



เทคนิคการแยกส่วนประกอบ และ โฮลต์-วินเทอร์ ที่ได้รับการปรับปรุง ด้วยขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬ: กรณีศึกษาการพยากรณ์

PM2.5 ใน 8 จังหวัดภาคเหนือของประเทศไทย

Decomposition and Holt-Winters Techniques Enhanced by Whale Optimization Algorithm: Case Study of PM2.5 Forecasting in 8 Northern Provinces of Thailand

ปรารธนา มินเสน¹, วฐา มินเสน^{2*}

¹ภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่ เชียงใหม่ 50300

²ศูนย์วิจัยวิทยาการข้อมูล ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ เชียงใหม่ 50200

Pradthana Minsan¹, Watha Minsan^{2*}

¹Department of Mathematics and Statistics, Faculty of Science and Technology,
Chiang Mai Rajabhat University, Chiang Mai 50300

²Data Science Research Center, Department of Statistics, Faculty of Science,
Chiang Mai University, Chiang Mai 50200

Received 29 October 2023; Received in revised 2 July 2024; Accepted 8 July 2024

บทคัดย่อ

การศึกษานี้มีจุดประสงค์เพื่อประเมินประสิทธิภาพของตัวแบบ การผสมผสานขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬกับโฮลต์-วินเทอร์ (WOA-HW) และการแยกส่วนประกอบ (WOA-D) ในการพยากรณ์ความเข้มข้น PM2.5 รายสัปดาห์ใน 8 จังหวัดภาคเหนือของไทย เมื่อเทียบกับตัวแบบแยกส่วนประกอบแบบคลาสสิก (Classic-D) และ ค้นหาแบบกริดของโฮลต์-วินเทอร์ (Classic-HW) โดยใช้ชุดข้อมูลฝึกฝนจำนวน 130 สัปดาห์ ผลการศึกษาพบว่า WOA-HW และ WOA-D มีประสิทธิภาพสูงกว่าตัวแบบคลาสสิกโดย WOA-D แสดงค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ที่ต่ำกว่า Classic-D อย่างชัดเจน ในขณะที่ WOA-HW มีค่า RMSE ที่ใกล้เคียงกับ Classic-HW แต่ใช้เวลาในการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดเร็วกว่า

ในการพยากรณ์ความเข้มข้นค่า PM2.5 ส่วนหน้าในระยะยาว 2 ปี โดยใช้ชุดข้อมูลทดสอบจำนวน 105 สัปดาห์ ใช้เกณฑ์ RMSE MAE และ MAPE เป็นเครื่องมือในการเปรียบเทียบ ผลลัพธ์แสดงว่าตัวแบบที่มีประสิทธิภาพมากที่สุดของแต่ละจังหวัดนั้นต่างกัน ตัวแบบ WOA-HW สำหรับจังหวัดลำปางและเชียงราย ตัวแบบ WOA-D สำหรับ

*ผู้รับผิดชอบบทความ: wathaminsan@gmail.com

จังหวัดแม่ฮ่องสอนและพะเยา ตัวแบบ Box-Jenkins สำหรับจังหวัดน่านและแพร่ ตัวแบบ Classic-HW สำหรับลำพูน และตัวแบบ Classic-D สำหรับจังหวัดเชียงใหม่ โดยการพยากรณ์ล่วงหน้า 2 ปีของทุกจังหวัดแสดงว่าความเข้มข้น PM2.5 มีฤดูกาลชัดเจนและสูงเกินค่าที่ส่งผลกระทบต่อสุขภาพในช่วงเดือนธันวาคมถึงเมษายน

คำสำคัญ: PM2.5; วิธีการหาค่าเหมาะที่สุดแบบวาท; แยกส่วนประกอบ; โฮลด์-วินเทอร์; บ็อกซ์-เจนกินส์; LSTM

Abstract

The objective of this study was to evaluate the effectiveness of two forecasting models: the hybrid Whale Optimization Algorithm with Holt-Winters (WOA-HW) and hybrid Whale Optimization Algorithm with Decomposition (WOA-D), in forecasting weekly PM2.5 concentrations in 8 provinces in Northern Thailand. These models were compared to classical decomposition (Classic-D) and grid search Holt-Winters (Classic-HW) models using a training dataset of 130 weeks. The results show that WOA-HW and WOA-D outperformed the classical models, with WOA-D exhibiting significantly lower RMSE than Classic-D. Although WOA-HW had RMSE values comparable to Classic-HW, it required less time to find the optimal parameters.

For long-term forecasts over two years, a test dataset of 105 weeks was used, with RMSE, MAE, and MAPE serving as evaluation metrics. The results indicated that the optimal model varied for each province: WOA-HW was best for Lampang and Chiang Rai, WOA-D for Mae Hong Son and Phayao, Box-Jenkins for Nan and Phrae, Classic-HW for Lamphun, and Classic-D for Chiang Mai. The two-year forecast for all provinces revealed a distinct seasonal pattern in PM2.5 concentrations, with levels exceeding health-impact thresholds from December to April.

Keywords: PM2.5; Whale Optimization Algorithm; Decomposition; Holt-Winters; Box-Jenkins; LSTM

1. บทนำ

การพยากรณ์อนุกรมเวลาเป็นกระบวนการในการคาดการณ์ค่าในอนาคตของอนุกรมเวลา วิธีการพยากรณ์อนุกรมเวลามีมากมายหลายวิธี หนึ่งในวิธีการพยากรณ์อนุกรมเวลาที่ได้รับคามนิยม คือ วิธีการโฮลต์-วินเทอร์ (Holt-Winters: HW) ซึ่งเป็นวิธีการพยากรณ์ที่มีประสิทธิภาพ อย่างไรก็ตามวิธีการ HW จำเป็นต้องกำหนดค่าพารามิเตอร์หลายตัว ซึ่งอาจทำให้การพยากรณ์ไม่แม่นยำถ้ากำหนดค่าพารามิเตอร์ไม่ดีเพียงพอ เพื่อเพิ่มประสิทธิภาพในการประมาณค่าพารามิเตอร์ของ HW ได้มีการศึกษาเกี่ยวกับการผสมรวมวิธีการ HW กับเมตาฮิวริสติกส์ (Metaheuristics) ซึ่งเป็นวิธีการค้นหาผลลัพธ์ที่เหมาะสมที่สุดจากพื้นที่ค้นหาขนาดใหญ่ เมตาฮิวริสติกส์มีหลายวิธี เช่น ขั้นตอนวิธีการหาค่าที่เหมาะสมแบบอาณานิคมมด (Ant Colony Optimization) ที่พัฒนาขึ้นโดย Dorigo [1] ในปี ค.ศ. 1992 ในวิทยานิพนธ์ระดับปริญญาเอกของเขา และนำมาพัฒนาต่อร่วมกับ Stützle [2] ในปี ค.ศ. 2004 ขั้นตอนวิธีอาณานิคมผึ้งเทียม (Artificial Bee Colony Algorithm) ที่พัฒนาโดย Karaboga ในปี ค.ศ. 2005 [3] ขั้นตอนวิธี Cuckoo Search (CS) ที่พัฒนาโดย Yang and Deb [4] ในปี ค.ศ. 2009 ขั้นตอนวิธีการหาค่าที่เหมาะสมแบบแมลงหวี่ (Fruit Fly Optimization) ซึ่งเป็นวิธีการที่นำเสนอโดย Pan [5] ในปี ค.ศ. 2011 และขั้นตอนวิธีการถ่ายละอองเรณูดอกไม้ (Flower Pollination Algorithm) ที่พัฒนาโดย Yang [6] ในปี ค.ศ. 2012

การศึกษาที่ผ่านมาพบว่า การผสมรวมวิธีการ HW กับเมตาฮิวริสติกส์สามารถปรับปรุงความแม่นยำของการพยากรณ์ได้ ตัวอย่างเช่น ในปี ค.ศ. 2010 Kaewpaengjuntra et al. [7] ได้ผสมรวม HW กับขั้นตอนวิธีอาณานิคมผึ้งเทียมเพื่อพยากรณ์การใช้ไฟฟ้าโดยรวมของประเทศไทย ในปี ค.ศ. 2013 Assis et al. [8] ได้ผสมรวม HW กับขั้นตอนวิธีการหาค่าที่เหมาะสมแบบอาณานิคมมดในการศึกษาลักษณะการรับส่งข้อมูล

ด้วยการใช้การวิเคราะห์การไหลแบบสองมิติเพื่อสร้างแบบจำลองพฤติกรรมรูปแบบการรับส่งข้อมูลในระบบเครือข่าย ในปี ค.ศ. 2018 Junta et al. [9] ได้ผสมรวม HW กับขั้นตอนวิธีการถ่ายละอองเรณูดอกไม้ เพื่อศึกษาการพยากรณ์ข้อมูลปริมาณการส่งออกสินค้าเกษตรรายเดือนจากเว็บไซต์ของสำนักงานเศรษฐกิจการเกษตรจำนวน 7 รายการ ในปี ค.ศ. 2020 Jiang et al. [10] ได้ผสมรวม HW กับขั้นตอนวิธีการหาค่าที่เหมาะสมแบบแมลงหวี่ ในการคาดการณ์ปริมาณการใช้ไฟฟ้ารายเดือน และในปี ค.ศ. 2023 Mauricio and Ostia [11] ได้ใช้ขั้นตอนวิธี Cuckoo Search (CS) เพื่อเพิ่มประสิทธิภาพวิธีการ HW ในบริบทของการพยากรณ์โหลดหม้อแปลงไฟฟ้า

การนำเมตาฮิวริสติกส์มาผสมรวมกับการประมาณค่าพารามิเตอร์ HW นั้นทำให้ตัวแบบ HW สามารถสร้างตัวแบบที่มีความคลาดเคลื่อนไปจากข้อมูลจริงน้อยลง วิธีการเมตาฮิวริสติกส์เหล่านี้จึงถูกนำมาทดลองใช้กับ HW เมื่อมีการนำเสนอวิธีการเมตาฮิวริสติกส์วิธีการใหม่ๆ อยู่เสมอ ในปี ค.ศ. 2016 ขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุดแบบวาฬ (Whale Optimization Algorithm: WOA) ที่ได้รับแรงบันดาลใจจากพฤติกรรมการล่าเหยื่อของวาฬหลังค่อม (Humpback Whale) ที่นำเสนอโดย Mirjalili and Lewis [12] วิธีนี้ได้รับความนิยมอย่างมากในฐานะขั้นตอนวิธีการหาค่าที่เหมาะสมที่ได้แรงบันดาลใจจากธรรมชาติที่สามารถประยุกต์ใช้ได้เป็นอย่างดีในการใช้งานด้านต่างๆ ในโลกแห่งความเป็นจริง จำนวนการอ้างอิง WOA แสดงให้เห็นถึงการเติบโตอย่างมาก คือ มีการอ้างอิง 37 ครั้งในปี 2016 และเพิ่มขึ้นเป็น 7,410 ครั้ง ในเดือนมีนาคม 2023 [13] และ Minsan et al. [14] ได้ใช้โซลเวอร์ (Solver) ของโปรแกรมเอกซ์เซล (Excel) เวอร์ชัน 2019 เปรียบเทียบประสิทธิภาพกับ WOA ซึ่งผลลัพธ์ออกมาว่า WOA เป็นวิธีการหาผลลัพธ์ในฟังก์ชันทดสอบ 16 ฟังก์ชันได้ดีที่สุดเป็นส่วนใหญ่ ซึ่งสะท้อนให้เห็นถึงความนิยมและผลกระทบบของ WOA ในการแก้ไขปัญหาการหาค่าที่เหมาะสมที่หลากหลาย

ในปี ค.ศ. 2023 Minsan and Minsan [15] ได้นำเสนอการผสมผสานกันระหว่าง WOA กับ เทคนิคการแยกส่วนประกอบรูปแบบบวกลบและ HW รูปแบบบวกลบ โดยประมาณค่าพารามิเตอร์ใน HW จำนวน 3 ตัว และประมาณค่าพารามิเตอร์ในเทคนิคการแยกส่วนประกอบจำนวน 14 ตัว ใช้พยากรณ์รายได้รัฐบาลของประเทศไทย 4 ส่วน ซึ่งพบว่าวิธีการผสมผสาน WOA ร่วมกับเทคนิคการแยกส่วนประกอบ และวิธีการผสมผสาน WOA ร่วมกับ HW ได้ผลลัพธ์ที่ดีกว่าวิธีแยกส่วนประกอบแบบคลาสสิก (Classic Decomposition: Classic-D) และ Box-Jenkins และในปีต่อมา Minsan and Minsan [16] ได้ต่อยอดการผสมผสานกันระหว่างตัวแบบการแยกส่วนประกอบและ HW ตัวแบบรูปแบบบวกลบและรูปแบบคูณ ร่วมกับ WOA ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือน ในภาคใต้ของประเทศไทย 4 แห่ง ซึ่งผลลัพธ์ในการผสมผสานนั้นก็ได้ผลลัพธ์ที่ดีเช่นเดียวกัน

ในการศึกษาที่ใช้วิธีการ WOA จาก Minsan and Minsan [15, 16] เพื่อประมาณค่าพารามิเตอร์ในวิธีการ HW ดังเช่นงานวิจัยที่ผ่านมา โดยมีจำนวนพารามิเตอร์ของตัวแบบที่ต้องประมาณจำนวน 3 ตัว และผสมผสานวิธีการ WOA กับ เทคนิคการแยกส่วนประกอบ (Decomposition: D) จำนวนพารามิเตอร์ที่ต้องประมาณจะเป็นไปตามลักษณะของข้อมูลที่ทำการศึกษา โดยการศึกษาเลือกข้อมูลความเข้มข้น PM_{2.5} ของ 8 จังหวัดภาคเหนือรายสัปดาห์ ที่ค่า PM_{2.5} เป็นปัญหาใหญ่ของภูมิภาคนี้มาโดยตลอดในช่วงทศวรรษนี้ เนื่องจากในช่วงประมาณเดือนมกราคมถึงเดือนเมษายนค่า PM_{2.5} จะสูงขึ้นจนก่อให้เกิดปัญหาสุขภาพกับประชาชน ดังนั้นจำนวนพารามิเตอร์ที่ต้องประมาณจำนวนมากถึง 54 ตัว ซึ่งจำนวนพารามิเตอร์ที่ต้องประมาณมากกว่า Minsan and Minsan [15, 16] เป็นการขยายขอบเขตของการประมาณค่าพารามิเตอร์ที่ยังคงใช้ประโยชน์จากความสามารถในการสำรวจและประเมินผลของ WOA ซึ่งเป็นวิธีการที่มีแนวโน้มว่าจะช่วยเพิ่มความแม่นยำและ

ประสิทธิภาพของตัวแบบการพยากรณ์ในการวิเคราะห์อนุกรมเวลา ในส่วนถัดไปจะกล่าวถึงการนำ WOA ไปผสมผสานกับ HW และ D อย่างครอบคลุมทั้งขั้นตอนการดำเนินการ รหัสเทียม และสูตรการคำนวณ

2. วิธีดำเนินการวิจัย

การศึกษานี้มีขั้นตอนวิธีการดำเนินการวิจัย 2.1 ถึง 2.4 ดังนี้

2.1 ขั้นตอนวิธีการค้นหาหาวาฬ

ขั้นตอนวิธีการค้นหาหาวาฬ [12, 14, 15, 16] ได้รับแรงบันดาลใจจากพฤติกรรมกรล่าเหยื่อของวาฬหลังค่อม WOA ได้รับการยอมรับสำหรับประสิทธิภาพในการแก้ไขปัญหาที่ซับซ้อนในงานด้านต่างๆ วาฬหลังค่อมจะปล่อยฟองอากาศออกมาเพื่อต้อนให้ฝูงปลารวมกลุ่ม เรียกว่า การสร้างฟองอากาศในรูปเกลียวล้อมรอบเหยื่อไว้ หรือ Bubble-Net Feeding โดยวาฬหลังค่อมจะดำน้ำลงไปและเริ่มสร้างฟองอากาศในรูปเกลียวรอบตัวเหยื่อและว่ายน้ำขึ้นไปบนผิวน้ำเพื่อกินเหยื่อวิธี WOA จะนำหลักการหาอาหารของวาฬมาใช้ในการสร้างแบบจำลองทางคณิตศาสตร์เพื่อหาค่าที่เหมาะสมที่สุด มีข้อกำหนดเบื้องต้นดังนี้ N คือ จำนวนวาฬ และ m คือ จำนวนพารามิเตอร์ ตำแหน่งของวาฬแต่ละตัว จะแสดงเป็น $X_i = (x_i^1, x_i^2, \dots, x_i^m), i \in \{1, 2, \dots, N\}$ ในระหว่างกระบวนการการหาค่าที่เหมาะสมที่สุด วาฬจะดำเนินการเคลื่อนไหว 3 ประเภท ซึ่งในแต่ละเวลา วาฬจะปรับตำแหน่งตนเองโดยดำเนินการอย่างใดอย่างหนึ่งใน 3 การกระทำเหล่านี้

2.1.1 ล้อมรอบเหยื่อ (Encircling Prey)

วาฬหลังค่อมทราบตำแหน่งของเหยื่อและล้อมพวกมันไว้ โดยกำหนดว่าคำตอบที่ดีที่สุดเป็นตำแหน่งของเหยื่อที่เป็นเป้าหมายหรือจุดที่ใกล้เคียงกับค่าที่เหมาะสมที่สุดจากนั้นตัวแทนของคำตอบอื่นๆ จะปรับปรุงตำแหน่งของตัวเองโดยอ้างอิงกับตำแหน่งของเหยื่อ เปรียบได้กับวาฬหลังค่อมที่พุ่งเข้าไปล้อมเหยื่อ

ซึ่งพฤติกรรมดังกล่าว ดังสมการที่ (1)

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D}, \quad (1)$$

โดยที่ $\vec{X}(t+1)$ เป็นเวกเตอร์ตำแหน่งใหม่ของวาฬ เมื่อ $\vec{X}^*(t)$ คือเวกเตอร์ตำแหน่งที่ดีที่สุดที่วาฬพบจนถึงขณะนี้ (t) และ \vec{A} คือ เวกเตอร์สัมประสิทธิ์แอมพลิจูด และ \vec{D} คือ เวกเตอร์ที่สร้างขึ้นแบบสุ่ม การเคลื่อนไหวนี้ช่วยให้วาฬสำรวจพื้นที่ค้นหาได้อย่างมีประสิทธิภาพและไปสู่ผลลัพธ์ที่น่าพอใจขึ้นในเวลาถัดไป ($t+1$) เวกเตอร์ \vec{A} และ \vec{D} คำนวณดังนี้

$$\vec{A} = 2 \cdot \vec{a} \cdot \vec{r} - \vec{a},$$

$$\vec{D} = |\vec{C} \cdot \vec{X}^*(t) - \vec{X}(t)| \text{ ที่ } \vec{C} = 2 \cdot \vec{r},$$

โดยที่ \vec{a} คือ สัมประสิทธิ์แอมพลิจูดที่ลดลงเชิงเส้นจาก 2 เป็น 0 ตลอดระยะเวลาของการทำซ้ำ เป็นการควบคุมการเคลื่อนที่ของวาฬในระยะเวลาสำรวจ (Exploration Phase) ในช่วงเริ่มต้นของกระบวนการค้นหา \vec{a} จะมีค่าสูง ซึ่งช่วยให้วาฬสามารถสำรวจพื้นที่ค้นหาได้อย่างกว้างขวาง เมื่อกระบวนการค้นหาดำเนินไป \vec{a} จะลดลง ซึ่งช่วยให้วาฬมุ่งเน้นไปที่พื้นที่ที่มีแนวโน้มว่าจะมีผลลัพธ์ที่ดี ส่วน \vec{r} คือ เวกเตอร์แบบสุ่มใน $[0, 1]$ ที่ใช้ในการกำหนดทิศทางการเคลื่อนที่ของวาฬในระยะเวลาสำรวจ การเคลื่อนที่ของวาฬจะขึ้นอยู่กับทิศทางของเวกเตอร์ \vec{r} และสัมประสิทธิ์แอมพลิจูด \vec{a} ส่วน \vec{C} คือ เวกเตอร์สัมประสิทธิ์ที่ใช้ในการควบคุมการเคลื่อนที่ของวาฬในระยะเวลาใช้ประโยชน์ (Exploitation Phase) การเคลื่อนที่ของวาฬจะขึ้นอยู่กับทิศทางของเวกเตอร์ \vec{C} และสัมประสิทธิ์แอมพลิจูด \vec{a}

2.1.2 การโจมตีด้วยฟองอากาศแบบเกลียว (Bubble-net Attacking)

การโจมตีด้วยฟองอากาศแบบเกลียวเกิดขึ้นเมื่อวาฬหลังค่อมโอบล้อมเหยื่อไว้ภายในวงกลมที่หดตัวหรือเคลื่อนที่ตามเส้นทางรูปเกลียว วาฬหลังค่อมจะแสดงพฤติกรรมการว่ายน้ำรอบเหยื่อโดยค่อยๆ บีบวงล้อมรอบเหยื่อหรือการโจมตีด้วยฟองอากาศแบบเกลียวเข้าไปอย่างใดอย่างหนึ่ง ในการจำลองพฤติกรรมนี้ วิธี WOA จะกำหนดความน่าจะเป็น

ร้อยละ 50 ระหว่างการเกิดพฤติกรรมการบีบวงล้อมรอบเหยื่อดังสมการที่ (1)

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D} \text{ ถ้า } p < 0.5,$$

และการโจมตีด้วยฟองอากาศแบบเกลียวดังสมการที่ (2) ดังนี้

$$\vec{X}(t+1) = \vec{D}' \cdot e^{i\pi} \cdot \cos(2\pi l) + \vec{X}^*(t) \text{ ถ้า } p \geq 0.5, \quad (2)$$

โดยที่ p คือ ค่าสุ่มใน $[0, 1]$, $\vec{D}' = |\vec{X}^*(t) - \vec{X}(t)|$ และฟังก์ชันระยะทางของวาฬตัวที่ i^{th} ไปยังเหยื่อ (ผลลัพธ์ที่ดีที่สุดที่ได้มาจนถึงขณะนี้) b เป็นค่าคงตัวสำหรับการกำหนดรูปร่างของเกลียวลอการิทึม และ l คือ ค่าสุ่มใน $[-1, 1]$ นอกเหนือจากเทคนิคการโจมตีด้วยฟองอากาศแบบเกลียวแล้ว วาฬหลังค่อมยังดำเนินการค้นหาเหยื่อแบบสุ่มอีกด้วย แบบจำลองทางคณิตศาสตร์สำหรับกระบวนการค้นหาดังหัวข้อต่อไป

2.1.3 การค้นหาเหยื่อ (Search for Prey)

กลไกการสำรวจนี้ช่วยให้วาฬสามารถเข้าสู่พื้นที่ต่างๆ ของพื้นที่ค้นหา เพิ่มโอกาสในการค้นพบผลลัพธ์ที่ดีกว่า แบบจำลองทางคณิตศาสตร์สำหรับระยะเวลาสำรวจเกี่ยวข้องกับการปรับปรุงตำแหน่งของวาฬแบบสุ่มตามสมการต่อไปนี้

$$\vec{D} = |\vec{C} \cdot \vec{X}_{\text{rand}} - \vec{X}(t)|, \vec{X}(t+1) = \vec{X}_{\text{rand}} - \vec{A} \cdot \vec{D}, \quad (3)$$

โดยที่ \vec{X}_{rand} เป็นเวกเตอร์ตำแหน่งแบบสุ่ม (วาฬแบบสุ่ม) ที่เลือกจากประชากรปัจจุบัน กลไกนี้ควบคู่กับการเน้นการสำรวจที่ $|\vec{A}| \geq 1$ เพิ่มความสามารถของขั้นตอนวิธีในการสำรวจผลลัพธ์ที่หลากหลายและป้องกันไม่ให้ติดอยู่ในค่าต่ำสุดเฉพาะที่ (Local Optima)

ถ้า $|\vec{A}| < 1$ จะดำเนินการตามสมการที่ (1) ที่วาฬจะทำการค้นหาอย่างละเอียดรอบๆ ค่าตอบที่ดีที่สุด การเคลื่อนไหวทั้ง 3 แสดงไว้ในรหัสเทียม (Pseudocode) ที่ให้ไว้ใน Figure 1 ซึ่งอธิบายรายละเอียดเกี่ยวกับขั้นตอนเหล่านี้

```

Input: the number of whales:  $N$ , the number of parameters:  $m$ , maximum iterations:  $T_{max}$ , time
limit:  $MaxTime$ , the fitness value fails to improve after a specified:  $T_{improve}$ , the bound of search area:
Range Initialize  $X_i = (x_i^1, x_i^2, \dots, x_i^m), X^*$ 

While ( $t < T_{max}$  or time  $< MaxTime$  or the fitness value fails to improve after a specified  $T_{improve}$ )
  For  $i = 1$  to  $N$ 
    Check if any search agent goes beyond the search space and amend it
    For  $j = 1$  to  $m$ 
       $p = rand[0,1]$ 
      Update  $a, r, A, C, D, D', b, l, X_{rand}$ 
      If  $p \geq 0.5$  then
        #Exploitation Phase: Update  $x_j^i$  the position of the current search agent by the Eq. (2)
      Elseif  $p < 0.5$  and  $|A| < 1$ 
        #Encircling Prey: Update  $x_j^i$  the position of the current search agent by the Eq. (1)
      Elseif  $p < 0.5$  and  $|A| \geq 1$ 
        #Exploration Phase: Update  $x_j^i$  the position of the current search agent by the Eq. (3)
      Endif
    End for
  End for
  Calculate  $fitness(X_i)$  using HW/Decomposition
  Update  $X^*$  if there is a better solution
   $t = t + 1$ 
End while
Return  $X^*$ 

```

Figure 1 Pseudo-code of WOA

2.2 การเตรียมข้อมูล

วัตถุประสงค์ของการวิจัยครั้งนี้เพื่อนำเสนอการผสานขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬกับไฮลด์-วินเทอร์ (Hybrid the Whale Optimization Algorithm with Holt-Winters: WOA-HW) และการแยกส่วนประกอบ (Hybrid the Whale Optimization Algorithm with Decomposition: WOA-D) การเลือกชุดข้อมูลที่น่ามาศึกษาควรเป็นชุดข้อมูลที่มีส่วนประกอบแนวโน้มและฤดูกาล ดังนั้นชุดข้อมูลสำหรับการศึกษานี้จึงเป็นข้อมูลความเข้มข้น

ของ PM2.5 ในภาคเหนือของประเทศไทย ที่โดยธรรมชาติมีลักษณะที่มีแนวโน้มและฤดูกาล

แหล่งของข้อมูลข้อมูลความเข้มข้นของ PM2.5 ได้จากกรมควบคุมมลพิษ กระทรวงทรัพยากรธรรมชาติและสิ่งแวดล้อมแห่งประเทศไทย [17] ข้อมูลนี้สามารถเข้าถึงได้จากเว็บไซต์อย่างเป็นทางการ Air4Thai ข้อมูลความเข้มข้นของ PM2.5 รายวันที่รวบรวมจาก 8 จังหวัดในภาคเหนือของประเทศไทย ได้แก่ เชียงใหม่ (CMI) ลำปาง (LPG) เชียงราย (CRI) แม่ฮ่องสอน (MSN) น่าน (NAN) ลำพูน (LPN)แพร่ (PRE) และพะเยา (PYO)

ตั้งแต่วันที่ 1 มกราคม พ.ศ. 2562 ถึง 30 มิถุนายน พ.ศ. 2566 โดยแต่ละแห่งมีจำนวนข้อมูล 1,642 วัน ทำความสะอาดชุดข้อมูลโดยปรับค่าสูญหายที่เกิดขึ้นในบางวัน โดยการแก้ไข (Interpolation) ด้วยวิธีการหาค่าเฉลี่ยอย่างง่าย (Simple Average) เป็นการปรับปรุงค่าสูญหาย โดยไม่มีผลกระทบต่อค่าเฉลี่ยรายวันของข้อมูลก่อนการปรับ ซึ่งยังคงแสดงให้เห็นถึงลักษณะทางสถิติของชุดข้อมูลด้วยค่าเฉลี่ยรายวันค่าเดิม หลังจากนั้นข้อมูลถูกรวมเข้าด้วยกันเพื่อคำนวณค่าเฉลี่ยรายสัปดาห์ของความเข้มข้น PM2.5 ส่งผลให้มีข้อมูลทั้งหมด 235 สัปดาห์

สำหรับวัตถุประสงค์ของการวิจัยนี้แบ่งออกเป็น 2 ประเด็น คือ เปรียบเทียบวิธีการที่นำเสนอกับวิธีการแบบคลาสสิก(Classical: Classic) และศึกษาตัวแบบที่ดีที่สุดที่จะใช้ในการพยากรณ์ล่วงหน้า ดังนั้นชุดข้อมูลแบ่งออกเป็นสองกลุ่มย่อยที่แตกต่างกัน กลุ่มย่อยแรกกำหนดให้เป็นชุดข้อมูลฝึกฝน (Train Dataset) ประกอบด้วย 130 สัปดาห์ เรียกช่วงนี้ว่า ระยะข้อมูลฝึกฝน (Train Dataset Phase) และถูกใช้สำหรับพัฒนาตัวแบบสำหรับวิธีการพยากรณ์ต่างๆที่กำลังพิจารณา และเป็นช่วงทดสอบตัวแบบที่นำเสนอ เปรียบเทียบคู่กับตัวแบบที่สร้างขึ้นด้วยวิธีแบบคลาสสิก กลุ่มย่อยที่สองที่เรียกว่าชุดข้อมูลทดสอบ (Test Dataset) ประกอบด้วย 105 สัปดาห์ เรียกช่วงนี้ว่า ระยะข้อมูลทดสอบ (Test Dataset Phase) โดยทุกตัวแบบที่สร้างขึ้นในระยะข้อมูลการฝึกฝนจะนำมาพยากรณ์ระยะยาวจำนวน 105 สัปดาห์หรือจำนวน 2 ปี โดยมีเป้าหมายคือ การพิจารณาตัวแบบพยากรณ์ระยะยาวที่มีความคลาดเคลื่อนน้อยที่สุด ซึ่งนำตัวแบบนั้นใช้ในการพยากรณ์ล่วงหน้าจากวันสุดท้ายของชุดข้อมูลที่มีออกไปอีก 2 ปี คือ พยากรณ์ล่วงหน้ารายสัปดาห์ตั้งแต่ 1 กรกฎาคม พ.ศ. 2566 ถึง 30 มิถุนายน พ.ศ. 2568 เพื่อเป็นประโยชน์สำหรับการตัดสินใจทางนโยบายของรัฐบาลและผู้สนใจในการศึกษา PM2.5

ดังนั้นชุดข้อมูลทดสอบที่กำหนดนี้จึงการออกแบบโดยเจตนาให้ครอบคลุมระยะเวลาการพยากรณ์ 2 ปี สอดคล้องกับการพยากรณ์ล่วงหน้าระยะยาว

2.3 ตัวแบบพยากรณ์

การกำหนดสัญลักษณ์ในการศึกษานี้

Y_t คือ ค่าข้อมูลจริง ณ เวลา t

\hat{Y}_t คือ ค่าพยากรณ์ ณ เวลา t

ϵ_t คือ ความคลาดเคลื่อนที่มีการแจกแจงปกติ และเป็นอิสระกัน มีค่าเฉลี่ยเท่ากับศูนย์ และความแปรปรวนคงที่ทุกช่วงเวลา

t คือ ช่วงเวลา มีค่าตั้งแต่ 1 ถึง n_1 หรือ n_2 หรือ n แล้วแต่กรณี

กรณีอยู่ในระยะข้อมูลฝึกฝน n_1 แทน จำนวนข้อมูลในอนุกรมเวลาชุดข้อมูลฝึกฝน ($n_1 = 130$)

กรณีอยู่ในระยะข้อมูลทดสอบ n_2 แทน จำนวนข้อมูลในอนุกรมเวลาชุดข้อมูลทดสอบ ($n_2 = 150$)

กรณีอยู่ในขั้นตอนการพยากรณ์ล่วงหน้า 1 กรกฎาคม 2566 ถึง 30 มิถุนายน 2568 n แทน จำนวนข้อมูลทั้งหมด ($n = 235$)

s คือ คาบของฤดูกาลมีค่าเท่ากับ 52 ($s = 52$)

2.3.1 วิธีแยกส่วนประกอบ (Decomposition Method)

วิธีที่แยกอนุกรมเวลาออกเป็นส่วนประกอบต่างๆ คือ แนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cycle) และส่วนประกอบไม่ปกติ (Irregular) โดยในการศึกษานี้เลือกศึกษาส่วนประกอบที่มีผลต่อการพยากรณ์ 2 ส่วนประกอบ คือ แนวโน้มและฤดูกาล รูปแบบวง

แนวโน้มกำหนดให้มีตัวแบบแนวโน้มเส้นตรง (Linear Trend Model)

ตัวแบบและตัวแบบพยากรณ์แนวโน้มเส้นตรง ดังสมการ (4) และ (5) ตามลำดับ ดังนี้

$$Y_t = \beta_0 + \beta_1 t + \epsilon_t \quad (4)$$

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t \quad (5)$$

เมื่อพารามิเตอร์ β_0, β_1 แทนระดับของข้อมูล และความชัน ตามลำดับ ส่วน β_0 และ β_1 เป็นตัวประมาณของ β_0 และ β_1 ตามลำดับ

เมื่อนำส่วนประกอบของข้อมูลอนุกรมเวลา มีแนวโน้มและฤดูกาลเข้ารวมกันจะกำหนดให้เป็นวิธีแยกส่วนประกอบรูปแบบบวก (Additive Decomposition) ที่เหมาะกับอนุกรมเวลาที่มีความแปรผันตามฤดูกาลคงที่

ตัวแบบแนวโน้มเส้นตรงฤดูกาลรูปแบบบวก ตัวแบบและตัวแบบพยากรณ์ดัง (6) และ (7) ตามลำดับ

$$Y_t = \beta_0 + \beta_1 t + S_t + \varepsilon_t \quad (6)$$

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t + \hat{S}_t \quad (7)$$

เมื่อพารามิเตอร์ S_t แทนความแปรผันตามฤดูกาล ณ เวลา t และ $S_t = S_i$ สำหรับ $i = 1, 2, 3, \dots, s$ เมื่อ t เป็นเวลาในฤดูกาลที่ i มีค่า $\sum_{i=1}^s S_i = 0$ ส่วน \hat{S}_t เป็นตัวประมาณของ S_t

ในการศึกษาการสร้างตัวแบบตามสมการที่ (7) จะดำเนินการตามขั้นตอนโดยจะเรียกว่า Classic-D [15, 16] เป็นเทคนิคการพยากรณ์อนุกรมเวลาที่แยกอนุกรมเวลาออกเป็นส่วนประกอบต่างๆ ได้แก่ ส่วนประกอบแนวโน้ม และฤดูกาล ขั้นตอนทั่วไปที่เกี่ยวข้องในการพยากรณ์ Classic-D มีดังต่อไปนี้

ขั้นที่ 1 การเตรียมข้อมูล รวบรวมข้อมูลอนุกรมเวลาในอดีตที่ต้องการใช้ในการพยากรณ์ ตรวจสอบให้แน่ใจว่าข้อมูลอยู่ในรูปแบบที่เหมาะสมและครอบคลุมช่วงเวลาเพียงพอ

ขั้นที่ 2 แสดงภาพอนุกรมเวลา สร้างกราฟข้อมูลอนุกรมเวลาเพื่อแสดงรูปแบบโดยรวม แนวโน้ม และความผันผวนตามฤดูกาล ขั้นตอนนี้ช่วยในการเข้าใจลักษณะของข้อมูลและตัดสินใจเลือกตัวแบบที่เหมาะสมกับลักษณะของข้อมูล โดยอาจจะใช้การทดสอบทางสถิติช่วยในการตัดสินใจ

ขั้นที่ 3 กำหนดช่วงฤดูกาล ระบุความยาวของรอบฤดูกาลในข้อมูล อาจเป็นรายวัน รายสัปดาห์ รายเดือน หรือรูปแบบอื่นใดที่วนซ้ำในช่วงเวลาที่กำหนด

ขั้นที่ 4 จัดแนวโน้มออกจากข้อมูล ลบส่วนประกอบแนวโน้มออกจากอนุกรมเวลาเพื่อให้เหลือเฉพาะส่วนประกอบฤดูกาล สามารถทำได้โดยใช้เทคนิคต่างๆ เช่น นำอนุกรมเวลาเดิมลบค่าเฉลี่ยเคลื่อนที่กลาง (สำหรับตัวแบบรูปแบบบวก)

ขั้นที่ 5 ประมาณค่าส่วนประกอบฤดูกาล คำนวณส่วนประกอบฤดูกาลโดยนำผลจากขั้นที่ 4 หาค่าเฉลี่ยของค่าแต่ละฤดูกาล ปรับปรุงส่วนประกอบฤดูกาลโดยนำแต่ละค่าเฉลี่ยฤดูกาลลบค่าเฉลี่ยโดยรวมของดัชนีฤดูกาล (สำหรับตัวแบบรูปแบบบวก)

ขั้นที่ 6 ลบส่วนประกอบฤดูกาลออก นำอนุกรมเวลาข้อมูลจริงลบผลจากขั้นที่ 5 (สำหรับตัวแบบรูปแบบบวก) เพื่อรับข้อมูลอนุกรมเวลาที่ไม่ฤดูกาล (การปรับการแปรผันตามฤดูกาล หรือ Adjustment of Seasonal Variation)

ขั้นที่ 7 ประมาณค่าส่วนประกอบแนวโน้ม คำนวณส่วนประกอบแนวโน้มโดยการถดถอยเชิงเส้น (Linear Regression) จากขั้นที่ 6

ขั้นที่ 8 สร้างตัวแบบการพยากรณ์ รวมส่วนประกอบแนวโน้มในขั้นที่ 7 ($\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t$) และส่วนประกอบฤดูกาลขั้นที่ 5 (\hat{S}_t) ที่คำนวณไว้เพื่อตัวแบบการพยากรณ์แนวโน้มและฤดูกาลตามสมการที่ (7)

ขั้นที่ 9 ประเมินและปรับปรุง ประเมินความแม่นยำของตัวแบบการพยากรณ์โดยเปรียบเทียบกับค่าจริง หากจำเป็นให้ปรับปรุงตัวแบบการพยากรณ์

2.3.2 วิธีโฮลต์-วินเทอร์ (Holt-Winters Method: HW)

วิธี HW เป็นหนึ่งในวิธีการทำให้เรียบ (Smoothing) เป็นวิธีการสร้างสมการพยากรณ์จากค่าสังเกตในอนุกรมเวลาบางส่วนหรือทั้งหมดโดยให้น้ำหนักกับค่าสังเกตในอนุกรมเวลาแตกต่างกันแล้วแต่ส่วนประกอบของอนุกรมเวลา ในกรณีที่ส่วนประกอบของข้อมูลอนุกรมเวลาที่มีแนวโน้มและฤดูกาล จะสร้างตัวแบบพยากรณ์ด้วยวิธีการทำให้เรียบของ HW รูปแบบบวกหรือแบบคูณ HW ใช้ค่าทำให้เรียบ 3 ค่า

ได้แก่ α, γ และ δ ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 สำหรับค่าระดับ α (Level Parameter) ค่าที่ใกล้เคียงกับ 1 บ่งชี้ว่าตัวแบบปรับให้เข้ากับการสังเกตล่าสุดอย่างรวดเร็ว ในขณะที่ค่าที่ใกล้ 0 จะให้ความสำคัญกับการสังเกตในอดีตมากกว่า ค่าแนวโน้ม γ (Trend Parameter) ค่าสูงช่วยให้ตัวแบบปรับตัวเข้ากับการเปลี่ยนแปลงของแนวโน้มได้อย่างรวดเร็วในค่าสังเกตล่าสุด ในขณะที่ค่าต่ำจะทำให้ตัวแบบตอบสนองต่อการเปลี่ยนแปลงของแนวโน้มล่าสุดน้อยลง และค่าฤดูกาล δ (Seasonal Parameter) เป็นอิทธิพลของฤดูกาลหรือดัชนีฤดูกาล ค่าที่สูงขึ้นส่งผลให้มีความยืดหยุ่นและความไวต่อความผันผวนของฤดูกาลในคาบฤดูกาลล่าสุดมากขึ้น ในขณะที่ค่าที่ต่ำกว่าจะทำให้ตัวแบบมีความทนทานต่อการเปลี่ยนแปลงตามฤดูกาลในคาบฤดูกาลล่าสุด โดยในงานวิจัยนี้ทีการณาศึกษารูปแบบบวก และในการค้นหาค่าพารามิเตอร์ที่เหมาะสมจะใช้วิธีการค้นหาแบบกริด (Grid Search) ที่เป็นเทคนิคหนึ่งในการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเกี่ยวข้องกับการเปลี่ยนแปลงค่าพารามิเตอร์ในทศนิยม 3 ตำแหน่ง ในอัตราเพิ่มครั้งละ 0.005 เริ่มจาก 0 ถึง 1 ส่งผลให้มีการวนซ้ำทั้งหมด $201^3 = 8,120,601$ ครั้ง เรียกวิธีการศึกษาใหม่นี้ว่า Classic-HW เมื่อการคำนวณสิ้นสุดจะเลือกพารามิเตอร์ที่ดีที่สุดที่พิจารณาจากค่าน้อยที่สุดของรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE)

รูปแบบบวก ตัวแบบและตัวแบบพยากรณ์ดัง (6)

และ (8) ตามลำดับ

$$\hat{Y}_{t+p} = \hat{T}_t + p\hat{\beta}_t + \hat{S}_{t-p+1+(p-1)\text{mod } s}, \text{ สำหรับ } p = 1, 2, \dots \quad (8)$$

เมื่อ \hat{Y}_{t+p} คือ ค่าพยากรณ์ล่วงหน้า ณ เวลา $t+p$

p จำนวนช่วงเวลาที่ต้องการพยากรณ์ล่วงหน้า

\hat{T}_t คือ ระดับของอนุกรมเวลา ณ เวลา t และ $\hat{\beta}_t$ คือ แนวโน้มของอนุกรมเวลา ณ เวลา t และ \hat{S}_t คือ ส่วนประกอบฤดูกาลของอนุกรมเวลา ณ เวลา t คำนวณได้ดัง (9) (10) และ (11)

$$\hat{T}_t = \alpha(\hat{Y}_t - \hat{S}_{t-s}) + (1-\alpha)(\hat{T}_{t-1} + \hat{\beta}_{t-1}), \quad (9)$$

$$\hat{\beta}_t = \gamma(\hat{T}_t - \hat{T}_{t-1}) + (1-\gamma)\hat{\beta}_{t-1}, \quad (10)$$

$$\hat{S}_t = \delta(\hat{Y}_t - \hat{T}_t) + (1-\delta)\hat{S}_{t-s}, \quad (11)$$

2.3.3 การผสมขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาทกับโฮลด์-วินเทอร์

การเลือกพารามิเตอร์มีผลกระทบอย่างมากต่อประสิทธิภาพของตัวแบบ ดังนั้นการประยุกต์ WOA เพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมของตัวแบบ HW [15, 16] จะต้องดำเนินการอย่างถูกต้อง มีขั้นตอนการดำเนินการดังนี้

ขั้นที่ 1 สร้างพารามิเตอร์เริ่มต้น ตำแหน่งของวาทแต่ละตัวแสดงถึงพารามิเตอร์สามตัว $\hat{X}_i = (\alpha, \gamma, \delta)$ ภายในขอบเขต [0, 1]

ขั้นที่ 2: เลือกการเคลื่อนไหว วาทแต่ละตัวเลือกการกระทำสำหรับการเคลื่อนไหวครั้งต่อไปโดยเลือกหนึ่งในสามการเคลื่อนไหว การเลือกนี้กำหนดว่าวาทจะเคลื่อนเข้าใกล้เหยื่อหรือขยายการค้นหาคามรัทสเทียบ Figure 1 โดยมีตัวแปรนำเข้าของ WOA คือ $N = 30, T_{\text{max}} = 1,000, \text{MaxTime} = 180 \text{ sec.}, T_{\text{improve}} = 50,$ และ $m = 3.$

ขั้นที่ 3 คำนวณความเหมาะสมของตัวแบบความเหมาะสมถูกคำนวณโดยประเมินจาก RMSE ของชุดข้อมูล โดยใช้ตำแหน่งของวาทแต่ละตัวในวิธี HW ดังนั้นค่าพารามิเตอร์ที่ให้ค่า RMSE ต่ำสุดในรอบนั้นจะสามารถตัดสินใจตำแหน่งที่ดีที่สุดได้และกำหนดเป็น (\hat{X}^*)

ขั้นที่ 4 กำหนดเกณฑ์การหยุด ขั้นตอน WOA จะสิ้นสุดลงเมื่อค่าความเหมาะสมไม่สามารถปรับปรุงได้หลังจากถึงจำนวนรอบที่กำหนด T_{improve} หรือถึงขีดจำกัดเวลา MaxTime หรือถึงจำนวนรอบสูงสุด T_{max} ณ จุดนี้พารามิเตอร์ที่ดีที่สุดจะถูกส่งออกไปใช้

ขั้นที่ 5 การประเมินประสิทธิภาพ การประเมินประสิทธิภาพของ HW ด้วยพารามิเตอร์ที่ดีที่สุด เราประเมินความแม่นยำของการพยากรณ์โดยวัดความคลาดเคลื่อนระหว่างค่าพยากรณ์กับค่าข้อมูลจริง

ฟังก์ชันวัตถุประสงค์ของ WOA-HW เป็นสมการต่อไปนี้

Objective Minimize $RMSE(\alpha, \gamma, \delta)$,

$$\text{Variable range } \begin{cases} 0 \leq \alpha \leq 1 \\ 0 \leq \gamma \leq 1 \\ 0 \leq \delta \leq 1 \end{cases}$$

ที่ซึ่ง $RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t - \hat{Y}_t)^2}$ โดย T คือ จำนวนข้อมูล

ในอนุกรมเวลา Y_t คือ ค่าข้อมูลจริง \hat{Y}_t คือ ค่าพยากรณ์ โดยวิธี WOA-HW ที่ได้ค่าพารามิเตอร์ที่ดีที่สุดจากขั้นที่ 4 จากขั้นที่ 1 ถึง 5 ใน WOA-HW นั้นใช้ขั้นตอนวิธี WOA ได้โดยตรงตาม Figure 1 รหัสเทียมของ WOA เนื่องจากว่าค่าพารามิเตอร์ของ HW มีช่วงเดียวกับขั้นตอนนี้วิธี WOA คือ $[0, 1]$

2.3.4 การผสมขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาทกับการแยกส่วนประกอบ

การเลือกพารามิเตอร์มีผลกระทบต่อประสิทธิภาพของตัวแบบ WOA-D [15, 16] ในการศึกษาขั้นตอนนี้ขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาทถูกใช้เพื่อแก้ปัญหาค่าพารามิเตอร์ $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6, \beta_7, \beta_8, \beta_9, \beta_{10}, \beta_{11}, \beta_{12}, \beta_{13}, \beta_{14}, \beta_{15}, \beta_{16}, \beta_{17}, \beta_{18}, \beta_{19}, \beta_{20}, \beta_{21}, \beta_{22}, \beta_{23}, \beta_{24}, \beta_{25}, \beta_{26}, \beta_{27}, \beta_{28}, \beta_{29}, \beta_{30}, \beta_{31}, \beta_{32}, \beta_{33}, \beta_{34}, \beta_{35}, \beta_{36}, \beta_{37}, \beta_{38}, \beta_{39}, \beta_{40}, \beta_{41}, \beta_{42}, \beta_{43}, \beta_{44}, \beta_{45}, \beta_{46}, \beta_{47}, \beta_{48}, \beta_{49}, \beta_{50}, \beta_{51}, \beta_{52}, \beta_{53}, \beta_{54}$ ซึ่งมีจำนวนพารามิเตอร์ 54 ตัวของการแยกส่วนประกอบ มีขั้นตอนการดำเนินการดังนี้

ขั้นที่ 1 กำหนดข้อจำกัดของพารามิเตอร์จำนวนส่วนประกอบแบบวาทโดยใช้การถดถอยเชิงเส้น จะได้ $\hat{Y}_t = \beta_0 + \beta_1 t$ แนะนำให้ตั้งค่าขอบเขตบน (Upper Bound Constraints) และขอบเขตล่าง (Lower Bound Constraints) สำหรับพารามิเตอร์ β_0 และ β_1 ตามสมการต่อไปนี้

Upper Bound Constraints: $\beta_0 = 1.2\beta_1$ และ $\beta_1 = 1.2\beta_0$,

Lower Bound Constraints: $\beta_0 = 0.8\beta_1$ และ $\beta_1 = 0.8\beta_0$.

โดยข้อจำกัดเหล่านี้มีผลเมื่อพารามิเตอร์เป็นค่าบวก ในทางกลับกันหากพารามิเตอร์เป็นลบให้สลับขอบเขตบนและล่าง ค่าคงตัวที่กำหนด 0.8 และ 1.2 ใช้ในการควบคุมส่วนประกอบแบบวาทให้อยู่ในช่วงที่เหมาะสมซึ่งสามารถปรับเปลี่ยนได้ โดยการลดค่าคงตัวเหล่านี้ลงจะทำให้ขอบเขตการค้นหาพารามิเตอร์ β_0 และ β_1 แคบลง ซึ่ง

ส่งผลให้กระบวนการค้นหาเร็วขึ้นแต่อาจส่งผลให้ผลลัพธ์สุดท้ายมีความแม่นยำน้อย และในทางกลับกันการเพิ่มค่าคงตัวเหล่านี้จะขยายขอบเขตการค้นหาพารามิเตอร์ β_0 และ β_1 ให้กว้างขึ้น ซึ่งอาจทำให้กระบวนการหาค่าที่เหมาะสมช้าลง แต่ส่งผลให้ผลลัพธ์สุดท้ายแม่นยำขึ้น อย่างไรก็ตามในการศึกษานี้แนะนำค่า 0.8 และ 1.2 เนื่องจากได้ทำการทดสอบเบื้องต้นอย่างเพียงพอสำหรับการกำหนดค่าพารามิเตอร์เหล่านี้แล้ว

การกำหนดขอบเขตความแปรผันฤดูกาลให้ขจัดส่วนประกอบแนวโน้มออกจากอนุกรมเวลา โดยใช้การหาผลต่างลำดับ 1 จะได้ $\Delta Y_t = Y_t - Y_{t-1}$ กำหนดข้อจำกัดขอบเขตบนและล่างสำหรับพารามิเตอร์ฤดูกาล $S_1, S_2, S_3, \dots, S_{22}$ ดังนี้

Upper Bound Constraints (US) +[ค่าแอมพลิจูดสูงสุดของ ΔY_t]

Lower Bound Constraints (LS) -[ค่าแอมพลิจูดต่ำสุดของ ΔY_t]

แอมพลิจูด คือความสูงสูงสุดของคลื่น ซึ่งในกรณีนี้หมายถึง ความสูงสุดของความผันแปรฤดูกาลของอนุกรมเวลา

ขั้นที่ 2 สร้างพารามิเตอร์เริ่มต้น ตำแหน่งของแต่ละวาทแทนค่าพารามิเตอร์ 54 ตัว ซึ่งคือ $X_t = (\beta_0, \beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6, \beta_7, \beta_8, \beta_9, \beta_{10}, \beta_{11}, \beta_{12}, \beta_{13}, \beta_{14}, \beta_{15}, \beta_{16}, \beta_{17}, \beta_{18}, \beta_{19}, \beta_{20}, \beta_{21}, \beta_{22}, \beta_{23}, \beta_{24}, \beta_{25}, \beta_{26}, \beta_{27}, \beta_{28}, \beta_{29}, \beta_{30}, \beta_{31}, \beta_{32}, \beta_{33}, \beta_{34}, \beta_{35}, \beta_{36}, \beta_{37}, \beta_{38}, \beta_{39}, \beta_{40}, \beta_{41}, \beta_{42}, \beta_{43}, \beta_{44}, \beta_{45}, \beta_{46}, \beta_{47}, \beta_{48}, \beta_{49}, \beta_{50}, \beta_{51}, \beta_{52}, \beta_{53}, \beta_{54})$ ภายในขอบเขต $[0, 1]$ ให้สังเกตว่าในเบื้องต้นสามารถให้ WOA ค้นหาค่าพารามิเตอร์ภายในขอบเขต $[0, 1]$ ได้เลย โดยไม่ต้องปรับเปลี่ยนขั้นตอนวิธีของ WOA ใดๆ ส่วนค่าพารามิเตอร์เหล่านั้นจะสามารถปรับเป็นหน่วยตามข้อมูลจริงในภายหลังก่อนคำนวณความเหมาะสมของตัวแบบ

ขั้นที่ 3 เลือกการเคลื่อนไหว วาทแต่ละตัว จะเลือกการกระทำสำหรับการเคลื่อนไหวครั้งต่อไป โดยเลือกหนึ่งในสามการเคลื่อนไหวตามขั้นตอนวิธีของ WOA การเลือกนี้กำหนดว่าวาทจะเคลื่อนเข้าใกล้เหยื่อหรือขยายการค้นหาตามรหัสเทียม Figure 1 โดยมีตัวแปรนำเข้าของ WOA คือ $N = 30$, $T_{\max} = 1,000$, $MaxTime = 180 \text{ sec}$, $T_{\text{improve}} = 50$, และ $m = 54$

ขั้นที่ 4 การปรับหน่วยพารามิเตอร์ ตั้งค่าขั้นตอนวิธี WOA ให้ค้นหาพารามิเตอร์ภายในขอบเขต [0, 1] จากขั้นที่ 2 ดังนั้นจำเป็นต้องปรับหน่วยของพารามิเตอร์ก่อนคำนวณค่าความเหมาะสมของตัวแบบในขั้นที่ 5 โดยใช้สมการต่อไปนี้

Original Value = Scaled Value x (Upper Bound Constraint - Lower Bound Constraint) + Lower Bound Constraint.

Original Value คือ ค่าเดิมหรือค่าตามหน่วยข้อมูลจริง Scaled Value คือ ค่าพารามิเตอร์ที่ได้จาก WOA ในช่วง [0, 1] สมการนี้จะช่วยแปลงค่าพารามิเตอร์ขั้นตอนวิธี WOA ในช่วง [0, 1] ให้กลับไปอยู่ในหน่วยตามข้อมูลจริง

หากค่าเดิมเป็น S_i ต้องมีการปรับฤดูกาลเพิ่มเติมสามารถคำนวณได้โดยใช้สูตรต่อไปนี้

$$\text{กรณีแยกส่วนประกอบรูปแบบบวก} \\ \text{Adjust } S_i = S_i - \sum_{i=1}^{52} S_i / 52, \text{ แล้ว } \sum_{i=1}^{52} S_i = 0. \\ (\text{หมายเหตุ: กรณีแยกส่วนประกอบรูปแบบคูณ} \\ \text{Adjust } S_i = 52 \times S_i / \sum_{i=1}^{52} S_i, \text{ แล้ว } \sum_{i=1}^{52} S_i = 52)$$

จากขั้นที่ 1 ถึง 4 ใน WOA-D ที่แสดงข้างต้นนั้นใช้ขั้นตอนวิธี WOA ได้โดยตรงตาม Figure 1 รหัสเทียมของ WOA เพียงแต่ว่าก่อนขั้นตอนการคำนวณ "Calculate fitness(X_i)" ให้ใช้ขั้นที่ 4 การปรับขนาดพารามิเตอร์ ซึ่งขั้นที่ 4 นั้นก็จะอ้างอิงขั้นที่ 1 ในการกำหนดข้อจำกัดของพารามิเตอร์ ดังนั้นอาจจะสรุปได้ว่าการประยุกต์ใช้ WOA กับวิธีแยกส่วนประกอบนั้น ขั้นที่ 1 และ 4 ที่กล่าวถึงในหัวข้อนี้เป็นส่วนที่สำคัญมากใน WOA-D

ขั้นที่ 5 คำนวณความเหมาะสมของตัวแบบความเหมาะสมถูกคำนวณโดยประเมินจาก RMSE ของชุดข้อมูล โดยใช้ตำแหน่งของวาทแต่ละตัวในวิธีแยกส่วนประกอบ ดังนั้นค่าพารามิเตอร์ที่ให้ค่า RMSE ต่ำสุดในรอบนั้นจะสามารถตัดสินตำแหน่งที่ดีที่สุดได้และกำหนดเป็น (X^*)

ขั้นที่ 6 และ 7 กำหนดเกณฑ์การหยุด และการประเมินประสิทธิภาพ เป็นดังนี้ WOA-HW

ฟังก์ชันวัตถุประสงค์ของ WOA-D เป็นสมการต่อไปนี้

$$\text{Objective Minimize RMSE}(\hat{\beta}_0, \hat{\beta}_1, \hat{S}_1, \dots, \hat{S}_{52}), \\ \text{Variable range } \begin{cases} 0.8\hat{\beta}_0 \leq \hat{\beta}_0 \leq 1.2\hat{\beta}_0 \\ 0.8\hat{\beta}_1 \leq \hat{\beta}_1 \leq 1.2\hat{\beta}_1 \\ LS \leq \hat{S}_i \leq US \text{ for } i=1,2,\dots,52 \end{cases}$$

ที่ซึ่ง $RMSE = \sqrt{\frac{1}{T} \sum_{i=1}^T (Y_i - \hat{Y}_i)^2}$ โดย T คือจำนวนข้อมูล

ในอนุกรมเวลา Y_i คือ ค่าข้อมูลจริง \hat{Y}_i คือ ค่าพยากรณ์โดยวิธี WOA-D ที่ได้ค่าพารามิเตอร์ที่ดีที่สุดจากขั้นที่ 6

2.3.5 การประเมินประสิทธิภาพ

การประเมินของการศึกษานี้แบ่งออกเป็นสองประเภทที่แตกต่างกัน

ประเภทแรกคือ "ระยะข้อมูลฝึกฝน" มีวัตถุประสงค์เพื่อระบุแนวทางการสร้างตัวแบบที่ดีที่สุดโดยการประเมินประสิทธิภาพว่าแนวทางใดให้ค่า RMSE ต่ำสุดในช่วงชุดข้อมูลฝึกฝน โดยที่ $RMSE = \sqrt{\frac{1}{n_1} \sum_{i=1}^{n_1} (Y_i - \hat{Y}_i)^2}$, n_1

หมายถึงความยาวของชุดข้อมูลฝึกฝน และ Y_i และ \hat{Y}_i หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลฝึกฝน ตามลำดับ

เนื่องจากในระยะข้อมูลฝึกฝนดำเนินการหาค่าเหมาะที่สุดอยู่บนฟังก์ชันวัตถุประสงค์ RMSE โดยสร้างตัวแบบให้มี RMSE ต่ำสุดจะเป็นตัวแบบที่ดีที่สุด ดังนั้นในระยะข้อมูลฝึกฝนจึงประเมินประสิทธิภาพด้วย RMSE โดยผลของค่า RMSE ในระยะข้อมูลฝึกฝนนี้จะได้ค่า RMSE ทั้งหมด 4 วิธีคือ RMSE ของ Classic-D Classic-HW WOA-D และ WOA-HW โดยจะเปรียบเทียบค่าที่ดีที่สุดของ RMSE เป็นคู่ๆกัน 2 คู่ คือ Classic-D เปรียบเทียบกับ WOA-D และ Classic-HW เปรียบเทียบกับ WOA-HW

ประเภทสองคือ “ระยะข้อมูลทดสอบ” มีวัตถุประสงค์เพื่อประเมินความสามารถในการพยากรณ์ล่วงหน้าของตัวแบบโดยให้ตัวแบบพยากรณ์ล่วงหน้าสองปีหรือ 105 สัปดาห์ เพื่อเปรียบเทียบประสิทธิภาพของ

ตัวแบบโดยละเอียด ในระยะนี้ใช้ตัวชี้วัดสำคัญ 3 ตัว ได้แก่ RMSE ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) และ ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ในการประเมินมีสูตรดังต่อไปนี้

$$RMSE = \sqrt{\frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \hat{Y}_i)^2}, \quad MAE = \frac{1}{n_2} \sum_{i=1}^{n_2} |Y_i - \hat{Y}_i|, \quad \text{และ} \quad MAPE = 100 \times \frac{1}{n_2} \sum_{i=1}^{n_2} |Y_i - \hat{Y}_i| / Y_i \quad \text{สำหรับ} \quad Y_i > 0,$$

n_2 หมายถึงความยาวของชุดข้อมูลทดสอบ และ Y_i และ \hat{Y}_i หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลทดสอบตามลำดับ

เนื่องจากการพยากรณ์อนุกรมเวลาในข้อมูลจริงย่อมมีความแปรผันของข้อมูลที่เกิดขึ้นได้ การแบ่งข้อมูลเป็นชุดข้อมูลฝึกฝนและทดสอบถ้าชุดข้อมูลทั้ง 2 มีลักษณะเดียวกันทุกประการ ความคลาดเคลื่อนที่ได้จากตัวแบบที่ดีที่สุด (ค่าความคลาดเคลื่อนต่ำสุด) จากชุดข้อมูลฝึกฝนก็จะตรงกันกับชุดข้อมูลทดสอบ แต่การพยากรณ์อนุกรมเวลาในข้อมูลจริงย่อมมีความแปรผันของข้อมูล ดังนั้นเพื่อเป็นประโยชน์ต่อการนำค่าพยากรณ์ล่วงหน้าไปใช้ การเพิ่มตัวแบบอื่นๆ ในการพยากรณ์จึงเป็นสิ่งสำคัญที่การศึกษานี้ ในระยะข้อมูลทดสอบจึงเพิ่มวิธีการ Box-Jenkins [18] ซึ่งเป็นตัวแบบที่นิยมใช้กันอย่างแพร่หลาย การระบุพารามิเตอร์ของ Box-Jenkins ในการศึกษานี้ทำได้โดยใช้ขั้นตอนต่างๆ หลายขั้นตอนเพื่อระบุตัวแบบรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่แบบมีฤดูกาล (Seasonal Autoregressive Integrated Moving Average: SARIMA(p,d,q)(P,D,Q)_s) ดังนี้

1. การเตรียมข้อมูล (Data Preparation)

การวิเคราะห์ข้อมูลกราฟอนุกรมเวลา และ ACF ดัง Figure 2, 3 และ 4 และ ใช้การทดสอบ Dickey-Fuller (DF) โดยตั้งลำดับสูงสุดที่ 52 เพื่อพิจารณาฤดูกาลตามเงื่อนไขเกณฑ์สารสนเทศของอะกะอิเกะ (Akaike information criterion: AIC) เพื่อพิจารณาความเป็นอนุกรมเวลาแบบคงที่ ถ้าไม่เป็นอนุกรมเวลาแบบคงที่ จะดำเนินการแปลงข้อมูลด้วยการหาลำดับที่ของการหาผล

ต่าง d และผลต่างฤดูกาลของอนุกรมเวลา D ของอนุกรมเวลา หรือการแปลงของบ็อกซ์-ค็อกซ์ (Box-Cox transformation) แก้ไขปัญหาเมื่อความแปรปรวนของอนุกรมเวลาไม่คงที่

2. การระบุตัวแบบ (Model Identification)

กำหนดขอบเขตค่า p, q ตั้งแต่ 0 ถึง 2 และ P, Q ตั้งแต่ 0 ถึง 1 ในการค้นหาพารามิเตอร์ที่เหมาะสม ใช้วิธีการการค้นหากริดเป็นเทคนิคที่ใช้ในการเรียนรู้ของเครื่อง (Machine Learning) เพื่อค้นหาไฮเปอร์พารามิเตอร์ (Hyperparameters) ที่เหมาะสมที่สุดสำหรับตัวแบบที่กำหนด ไฮเปอร์พารามิเตอร์ คือ พารามิเตอร์ที่ตั้งค่าไว้ก่อนกระบวนการเรียนรู้จะเริ่มต้นในกรณีนี้ คือ ค่าพารามิเตอร์ที่สามารถกำหนดตัวแบบ SARIMA(p,d,q)(P,D,Q)_s ดังนั้นชุดค่าผสมต่าง ๆ เกิดจากผลคูณคาร์ทีเซียน (Cartesian) ของค่าพารามิเตอร์อย่างเป็นระบบเพื่อระบุตัวแบบที่เหมาะสมที่สุดตามเกณฑ์ที่กำหนด

ขั้นตอนที่สำคัญของการค้นหากริดจึงอธิบายได้ดังนี้

2.1 กำหนดชุดของค่าที่เป็นไปได้สำหรับแต่ละพารามิเตอร์ p, q ตั้งแต่ 0 ถึง 2 และ P, Q ตั้งแต่ 0 ถึง 1

2.2 สร้างกริดโดยใช้ผลคูณคาร์ทีเซียนของค่าที่เป็นไปได้สำหรับแต่ละพารามิเตอร์

2.3 สำหรับแต่ละจุดในกริด สร้างตัวแบบ SARIMA(p,d,q)(P,D,Q)₂₂ ตามพารามิเตอร์ในกริดที่กำหนดนั้น

2.4 คำนวณค่าประเมินความเหมาะสมของตัวแบบ โดยในงานวิจัยนี้ใช้ค่า AIC เป็นเกณฑ์ที่กำหนด

2.5 ทำซ้ำขั้นตอนที่ 3 และ 4 ทุกจุดของกริด

2.6 เรียงลำดับตัวแบบเหมาะสมตามค่า AIC จากน้อยไปมาก ดังนั้นจะได้ค่าพารามิเตอร์ของ p, q, P และ Q และ AIC ทุกตัวแบบที่เป็นไปตามแต่ละจุดในกริด

3. การตรวจสอบความเหมาะสมของตัวแบบ (Model Validation)

เลือกตัวแบบที่มีค่า AIC ต่ำที่สุดและดำเนินการขั้นตอนต่อไปจนกว่าตัวแบบจะผ่านการวิเคราะห์ค่าความคลาดเคลื่อนทั้งหมด ($e = Y - \hat{Y}$) ถ้าผ่านขั้นตอนเหล่านี้ทั้งหมด ตัวแบบนั้นจะเป็นตัวแบบที่เหมาะสมในการพยากรณ์

ขั้นตอนการวิเคราะห์ค่าความคลาดเคลื่อน

3.1 ค่าความคลาดเคลื่อนมีการแจกแจงปกติ โดยสถิติการทดสอบคอลโมโกรอฟ-สมิรันอฟ

3.2 ค่าความคลาดเคลื่อนเป็นอิสระกัน โดยสถิติการทดสอบ Ljung-Box

3.3 ค่าความคลาดเคลื่อนมีค่าเฉลี่ยเท่ากับศูนย์ โดยสถิติการทดสอบที

3.4 ค่าความคลาดเคลื่อนมีความแปรปรวนคงที่ทุกช่วงเวลา โดยสถิติการทดสอบของเลวิน

โดยผลลัพธ์ตามขั้นตอนการดำเนินการของวิธีการ Box-Jenkins นี้ เป็นไปตามการศึกษาของ Minsan et. al [19] และเพิ่มวิธีหน่วยความจำระยะสั้นแบบยาว (Long Short-term Memory: LSTM) [20] ที่เป็นวิธีการเรียนรู้ของเครื่องที่กำลังเป็นที่นิยมในการศึกษาด้วย ประกอบกับ Singhaworawong [21] ได้ใช้ LSTM ในการพยากรณ์ PM2.5 รายชั่วโมงของจังหวัดเชียงใหม่ ซึ่งได้ผลลัพธ์ที่ดี จึงนำมาใช้เป็นแนวคิดเพื่อประยุกต์ใช้ในงานวิจัย โดยกำหนดค่าของไฮเปอร์พารามิเตอร์ ดังนี้

ฟังก์ชันความสูญเสีย (Loss Function) เป็นวิธีคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error) ตัวเพิ่มประสิทธิภาพ (Optimizer) เป็นวิธี nadam ทำการฝึกสอน (Epoch) จำนวน 100 ครั้ง โดยการตั้งค่านี้เป็นการสมดุลระหว่างการวนซ้ำที่เพียงพอที่จะเรียนรู้รูปแบบที่ซ่อนอยู่ในข้อมูลอนุกรมเวลา ได้คำตอบที่เหมาะสมโดยไม่ใช้เวลาในการวนซ้ำมากเกินไป และไม่เกิดปัญหาฟิตมากเกินไป (Overfitting)

จำนวนเซลล์ประสาทเทียม (Neurons) ในเลเยอร์ เท่ากับ 25 50 และ 75 เลือกเพื่อสำรวจระดับความซับซ้อนของตัวแบบที่แตกต่างกัน จำนวนที่ต่ำกว่า เช่น 25 และ 50 ช่วยให้ตัวแบบเรียนรู้แบบไม่ซับซ้อน ในขณะที่จำนวนที่สูงกว่า เช่น 75 ช่วยให้ตัวแบบสามารถตรวจสอบความสัมพันธ์ที่ซับซ้อนมากขึ้นในข้อมูล โดยค่าที่กำหนดนี้ให้ความสมดุลที่ดีระหว่างประสิทธิภาพของตัวแบบและประสิทธิภาพในการคำนวณ ทำให้แบบตัวแบบสามารถจับรูปแบบที่จำเป็นโดยไม่ต้องคำนวณมากเกินไป

จำนวนข้อมูลย้อนหลัง (Look Back) เท่ากับ 26 52 และ 104 กำหนดแบบสอดคล้องกับข้อมูลรายสัปดาห์ โดยตรวจสอบรูปแบบตามฤดูกาลที่สำคัญ คือ กำหนด 26 สัปดาห์ครอบคลุมครึ่งปี กำหนด 52 สัปดาห์ครอบคลุมหนึ่งปีเต็ม และ 104 สัปดาห์ครอบคลุมสองปี ตัวเลือกนี้ช่วยให้แน่ใจว่าตัวแบบจะตรวจสอบการเปลี่ยนแปลงตามฤดูกาลทั้งระยะสั้นและระยะยาวได้

ผลของค่า RMSE MAE และ MAPE ในระยะข้อมูลทดสอบนี้จะได้ค่าแต่ละค่าทั้งหมด 6 วิธีคือ Classic-D Classic-HW WOA-D WOA-HW Box-Jenkins และ LSTM โดยจะเปรียบเทียบค่าที่ต่ำที่สุดของ RMSE MAE และ MAPE ใน 6 วิธีเหล่านั้น เพื่อใช้ในการตัดสินใจตัวแบบที่ดีที่สุดในการพยากรณ์ล่วงหน้า

การทดลองดำเนินการในสภาพแวดล้อม Google Colab [22] ซึ่งให้สิทธิ์เข้าถึงความสามารถในการเขียนโปรแกรม Python โดยอัตโนมัติ คอมพิวเตอร์

CPU Intel(R) Core(TM) i5-9400 @ 2.90GHz, RAM 16GB, ทำงานบนระบบปฏิบัติการ Windows 11

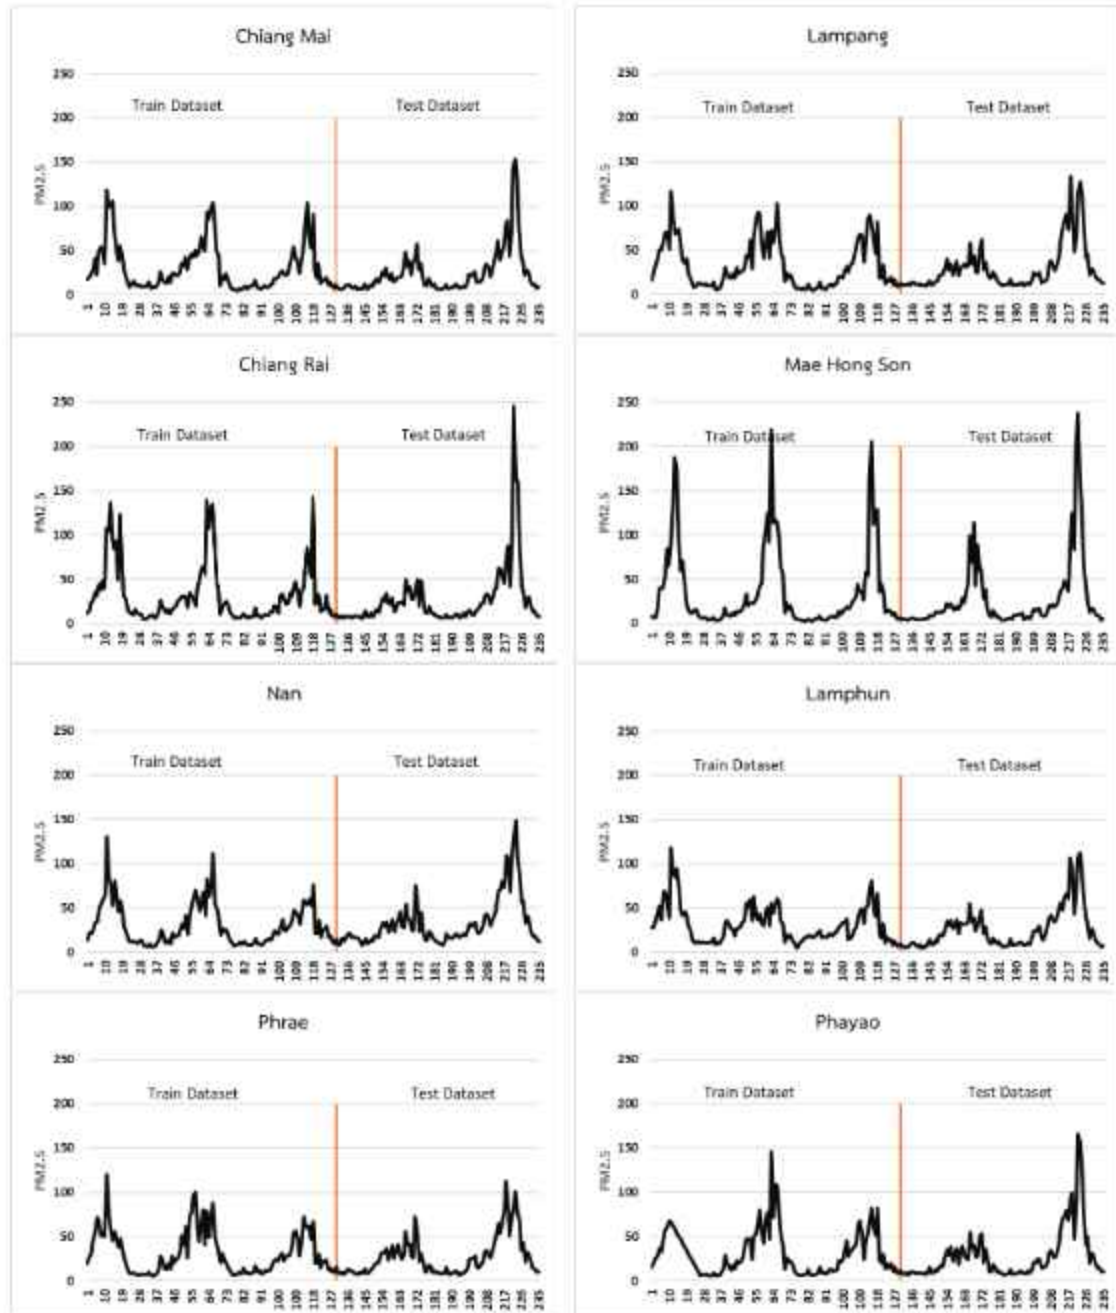


Figure 2 Weekly PM2.5 actual data of 8 northern provinces

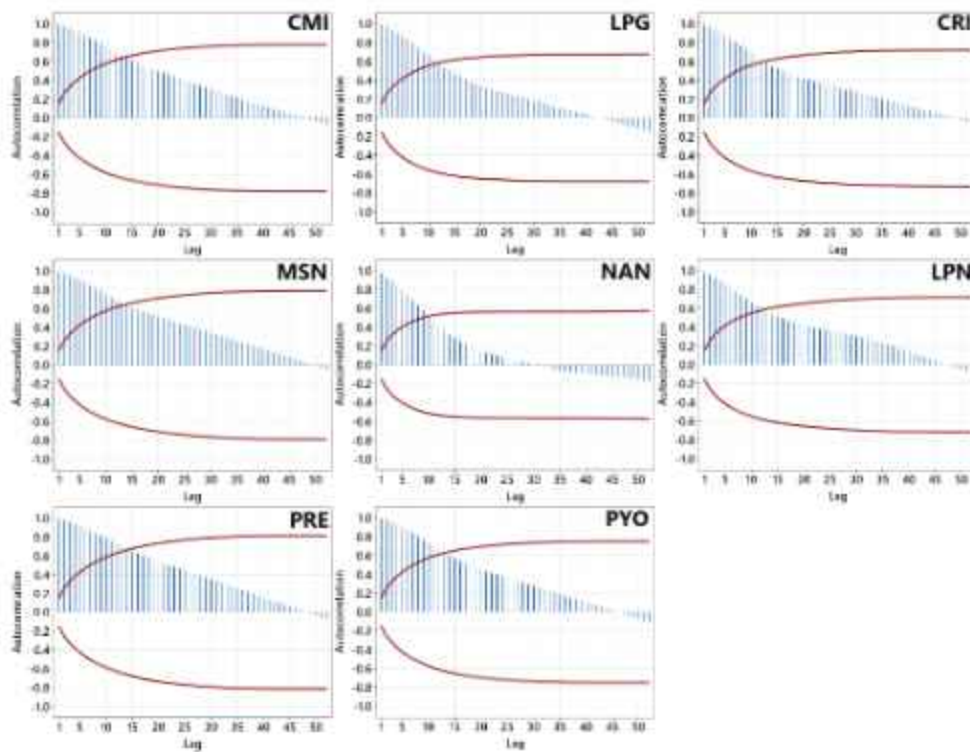


Figure 3 ACF of the deseasonalization time series data of 8 northern provinces




Figure 4 ACF of the detrended time series data of 8 northern provinces

3. การทดลองและการวิเคราะห์

3.1 ผลลัพธ์ของการวิเคราะห์ลักษณะการเคลื่อนไหวของอนุกรมเวลา

การวิเคราะห์ลักษณะการเคลื่อนไหวของอนุกรมเวลาโดยวิธีการวิเคราะห์เบื้องต้นจากราฟอนุกรมเวลาของข้อมูลตาม Figure 2 ได้ผลดังนี้ ค่า PM2.5 ในทุกจังหวัดภาคเหนือตอนบนปรากฏเห็นความแปรผันตามฤดูกาลชัดเจน โดยคาบของฤดูกาลเป็นช่วงเวลา 1 ปี ดังนั้น ในชุดข้อมูลรายสัปดาห์จึงตัดสัปดาห์ของฤดูกาลคือ 52 สัปดาห์ ในการตัดสินใจเกี่ยวกับแนวโน้มถ้าทดลองแบ่งส่วนข้อมูล 2.5 ปี ตามกำหนดข้อมูลชุดฝึกฝนคือตั้งแต่ พ.ศ. 2562 ถึง พ.ศ. 2564 พบว่าค่า PM2.5 มีแนวโน้มลดลงเล็กน้อย แต่ถ้าทดลองแบ่งส่วนข้อมูล 3.5 ปี ตั้งแต่ปี พ.ศ. 2562 ถึง พ.ศ. 2565 พบว่า ค่ามีแนวโน้มลดลงมากกว่าพิจารณา 2.5 ปี และถ้าไม่แบ่งข้อมูลเลยใช้ข้อมูล 4.5 ปี พบว่า ข้อมูลส่วนใหญ่ยังมีแนวโน้มลดลงแต่ลดลงน้อยกว่าการทดลองแบ่งส่วนข้อมูล 3.5 ปี และมี 3 จังหวัดที่มีแนวโน้มเพิ่มขึ้นคือจังหวัดลำปาง น่าน และพะเยา สาเหตุเพราะค่า PM2.5 ในปี พ.ศ. 2566 รุนแรงจาก 4 ปีก่อนหน้าอย่างมาก จากข้อมูลลักษณะการเคลื่อนไหวของอนุกรมเวลาเบื้องต้นนี้ การคาดการณ์แนวโน้มในอนาคตจึงอาจจะเป็นเรื่องยากพอสมควร ในการศึกษาจึงตัดสินใจว่าข้อมูลมีแนวโน้ม โดยแนวโน้มกับฤดูกาลมีความสัมพันธ์แบบบวก เนื่องจากถ้าตัดสัปดาห์จากเฉพาะชุดข้อมูลฝึกฝนแนวโน้มกับฤดูกาลจะมีความสัมพันธ์แบบคูณถ้าใช้ตัวแบบคูณนี้แนวโน้มที่ลดลงในช่วงชุดข้อมูลฝึกฝนจะทำให้ขนาดความแปรผันตามฤดูกาลลดลงด้วยซึ่งจะทำให้การคาดการณ์ล่วงหน้าคลาดเคลื่อนมาก โดยเฉพาะเมื่อนำผลการพยากรณ์ล่วงหน้าไปทดสอบกับชุดข้อมูลการทดสอบในปี พ.ศ. 2566 (ปีที่ 4.5) เพราะปีนี้มีความรุนแรง PM2.5 มาก นี่เป็นสาเหตุในการศึกษาครั้งนี้ใช้ตัวแบบรูปแบบบวก ในการศึกษาทั้ง HW และวิธีแยกส่วนประกอบ

การตัดสินใจเกี่ยวกับแนวโน้มและฤดูกาลสามารถใช้ฟังก์ชันสหสัมพันธ์ในตัว (Autocorrelation Function: ACF) ช่วยพิจารณาได้ดัง Figure 3 และ 4 โดย Figure 3 เป็น ACF ของข้อมูลแต่ละจังหวัดที่ขจัดฤดูกาล และ Figure 4 เป็น ACF ของข้อมูลแต่ละจังหวัดที่ขจัดแนวโน้ม โดยทั้ง 2 รูปนี้ยังเป็นตัวใช้ในการสร้างตัวแบบ Box-Jenkins อีกด้วย ทั้งนี้การตัดสินใจก็สอดคล้องกับการตัดสินใจด้วยการวิเคราะห์ลักษณะการเคลื่อนไหวของอนุกรมเวลา

3.2 การวิเคราะห์ประสิทธิภาพการเปรียบเทียบในรายละเอียดข้อมูลฝึกฝน

เพื่อประเมินประสิทธิภาพของตัวแบบ WOA-HW และ WOA-D ในการพยากรณ์ความเข้มข้นของ PM2.5 การศึกษานี้ได้ดำเนินการวิเคราะห์เปรียบเทียบกับตัวแบบการพยากรณ์แบบคลาสสิกสองแบบ ได้แก่ Classic-D และ Classic-HW เมื่อนำไปใช้กับชุดข้อมูลเดียวกัน คือ ข้อมูลอนุกรมเวลาความเข้มข้นค่า PM2.5 รายสัปดาห์ 8 จังหวัดภาคเหนือในชุดข้อมูลฝึกฝนได้ผลตาม Table ที่ 1

ความสามารถในการปรับแต่งพารามิเตอร์ของขั้นตอนวิธี WOA สามารถผสมเข้ากับตัวแบบ HW และการแยกส่วนประกอบได้อย่างมีประสิทธิภาพ ส่งผลให้ค่า RMSE ต่ำลงเมื่อเทียบกับวิธีการแบบคลาสสิก แสดงให้เห็นว่าการผสม WOA ช่วยทำให้ฟังก์ชันวัตถุประสงค์ RMSE ต่ำลงมากกว่าใช้วิธีการแบบคลาสสิก

ในการเปรียบเทียบแบบคู่ โดยคู่แรกระหว่างตัวแบบ WOA-D และ Classic-D ตัวแบบ WOA-D แสดงให้เห็นค่า RMSE ที่ต่ำกว่าอย่างมากเมื่อเทียบกับ Classic-D ซึ่งบ่งชี้ว่าความสามารถในการหาค่าที่เหมาะสมที่สุดของพารามิเตอร์ WOA ให้ผลที่ดีเหนือกว่าวิธีการแบบคลาสสิกในทุกชุดข้อมูล

ในการเปรียบเทียบคู่ที่สอง WOA-HW และ Classic-HW ค่า RMSE มีค่าใกล้เคียงกันมากจะแตกต่างกันก็ระดับทศนิยม 1 ตำแหน่งเป็นต้นไป จากชุดข้อมูลอนุกรมเวลา 8 จังหวัด พบว่า ค่าต่ำสุดของ RMSE ในทั้งสองวิธีนั้นเท่ากันคือ WOA-HW ชนะ 4 ชุดข้อมูล คือ ลำปาง เชียงราย ลำพูน และพะเยา ส่วน Classic-HW

ขณะที่ชุดข้อมูล เชียงใหม่ แม่ฮ่องสอน น่าน และแพร่ อย่างไรก็ตาม ต้นทุนด้านเวลาคำนวณอาจเป็นปัจจัยที่จะต้องนำมาพิจารณา เนื่องจากว่า ในการทดลองของการศึกษานี้ การค้นหาแบบกริด ซึ่งเกี่ยวข้องกับการเปลี่ยนแปลงค่าพารามิเตอร์ 3 ค่าได้แก่ α, γ และ δ ในระดับทศนิยม 3 ตำแหน่ง ที่อัตราเพิ่มแต่ละค่าครั้งละ 0.005 เริ่มจาก 0 ถึง 1 ส่งผลให้มีการวนซ้ำทั้งหมด 8,120,601 ครั้ง ที่เป็นการค้นหาค่าพารามิเตอร์ที่เหมาะสมกับฟังก์ชันวัตถุประสงค์ที่ละเอียดมาก ด้วยความละเอียดระดับนี้ทำให้การทดลองด้วยไพทอน (Python) บนกูเกิลคอลลาบ (Google Colab) ใช้เวลาเฉลี่ย

1 ชั่วโมง ส่วนเบี่ยงเบนมาตรฐาน 2 นาที ต่อ 1 จังหวัด ในการประมวลผลของฟังก์ชันวัตถุประสงค์ ส่วนการประมวลผล WOA-HW ด้วยไพทอนใช้เวลาเฉลี่ย 48 วินาที ส่วนเบี่ยงเบนมาตรฐาน 2 วินาที ต่อ 1 จังหวัดในการประมวลผลของฟังก์ชันวัตถุประสงค์ (โดยที่ Minsan and Minsan [15, 16] และงานวิจัยนี้สามารถหาค่าพารามิเตอร์ที่เหมาะสมโดยการประมวลผลตามขั้นตอนวิธีที่นำเสนอเพียงครั้งเดียวก็ได้คำตอบที่ดีโดยไม่ต้องทำซ้ำ) สรุปได้ว่าการนำ WOA มาใช้กับวิธีการ HW และการแยกส่วนประกอบ ช่วยให้สามารถปรับแต่งตัวแบบได้แม่นยำและมีเวลาในการค้นหาที่เหมาะสม

Table 1 Training Dataset RMSE by Province

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	9.63899	10.97138	14.63914	16.35235	10.79831	10.01703	10.98414	11.22043
Classic-D	10.73072	13.84824	17.18191	20.45834	12.59933	12.43616	14.16146	15.05965
WOA-HW	13.98683	17.19809	21.47516	26.30601	16.40176	15.10299	17.04539	16.72952
Classic-HW	13.97959	17.19810	21.47518	26.30559	16.04056	15.10300	17.04403	16.72953

Note: The lowest RMSE value between WOA-D and Classic-D, and between WOA-HW and Classic-HW is bolded

3.3 การวิเคราะห์ประสิทธิภาพการเปรียบเทียบในรายละเอียดข้อมูลทดสอบ

การสรุปตัวแบบที่มีประสิทธิภาพของแต่ละจังหวัดในชุดข้อมูลทดสอบเพื่อเลือกตัวแบบที่มีประสิทธิภาพดีที่สุดในพยากรณ์ล่วงหน้า พิจารณาจาก Table ที่ 2 3 และ 4 แสดงค่า RMSE MAE และ MAPE ตามลำดับ โดยจะเลือกตัวแบบที่มีค่าต่ำสุดในเกณฑ์ทั้ง 3 มากที่สุดถือเป็นตัวแบบที่มีประสิทธิภาพดีที่สุด

- จังหวัดเชียงใหม่เลือกตัวแบบ Classic-D เพราะมีค่า RMSE และ MAPE ต่ำสุด
- จังหวัดลำปางเลือกตัวแบบใดก็ได้ใน 3 ตัวแบบนี้คือ WOA-HW มีค่า RMSE ต่ำที่สุด Classic-HW มีค่า MAE ต่ำที่สุด และ Classic-D มีค่า MAPE ต่ำที่สุด ในงานวิจัยนี้เลือก WOA-HW ในการพยากรณ์ล่วงหน้า
- จังหวัดเชียงรายเลือกตัวแบบ WOA-HW เพราะมีค่า MAE และ MAPE ต่ำสุด

- จังหวัดแม่ฮ่องสอนเลือกตัวแบบใดก็ได้ใน 3 ตัวแบบนี้คือ WOA-D มีค่า RMSE ต่ำที่สุด LSTM มีค่า MAE ต่ำที่สุด และ Box-Jenkins มีค่า MAPE ต่ำที่สุดในงานวิจัยนี้เลือก WOA-D ในการพยากรณ์ล่วงหน้า
- จังหวัดน่านเลือกตัวแบบ Box-Jenkins เพราะมีค่า RMSE MAE และ MAPE ต่ำสุด ใช้ Ln ในการแปลงข้อมูลและได้ตัวแบบ SARIMA(2,1,0)(0,1,1)₂₂
- จังหวัดลำพูนเลือกตัวแบบ Classic-HW เพราะมีค่า RMSE MAE และ MAPE ต่ำสุด
- จังหวัดแพร่เลือกตัวแบบ Box-Jenkins เพราะมีค่า MAE และ MAPE ต่ำสุด ใช้ Ln ในการแปลงข้อมูลและได้ตัวแบบ SARIMA(1,1,1X0,1,0)₂₂
- จังหวัดพะเยาเลือกตัวแบบ WOA-D เพราะมีค่า RMSE และ MAE ต่ำสุด

Table 2 RMSE Metrics for Each Province's Testing Dataset

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	23.1066	24.0376	29.7050	25.3191	25.8858	22.2615	19.7992	22.5871
WOA-HW	22.4704	20.5950	28.0672	27.7104	31.7598	16.2253	16.4673	23.3082
Classic-D	21.8446	24.9215	31.0733	30.6131	25.1791	21.7060	21.5414	24.9190
Classic-HW	22.0666	20.5951	28.0641	27.7424	23.8451	16.2212	16.4660	23.3035
Box-Jenkins	24.0092	24.2997	35.3172	28.8855	22.5499	17.4173	16.8644	23.5297
LSTM	24.6521	28.6177	43.9556	26.7570	23.9249	18.3271	18.7947	26.2028

Note: The lowest value for each province is bolded

Table 3 MAE Metrics for Each Province's Testing Dataset

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	14.4982	16.9714	17.7679	13.6246	19.0599	14.7432	13.9808	12.5994
WOA-HW	12.6768	13.1074	15.4342	13.4418	23.1809	10.6340	10.6631	12.6384
Classic-D	14.3271	16.8168	18.6476	15.1466	18.3419	13.8492	14.8273	15.1587
Classic-HW	12.1324	13.1065	15.4371	13.5613	15.2835	10.6305	10.6631	12.6358
Box-Jenkins	12.8686	15.1068	21.8719	13.4957	13.5623	11.4518	10.4930	13.1559
LSTM	12.7400	19.8306	24.5086	12.6958	14.8416	11.7020	13.6729	13.8013

Note: The lowest value for each province is bolded

Table 4 MAPE Metrics for Each Province's Testing Dataset

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	61.4543	62.3862	69.0285	57.5336	61.7411	55.7308	56.4822	43.9754
WOA-HW	49.6047	45.8028	63.1640	44.7999	72.4274	51.6015	40.4787	42.7960
Classic-D	40.7040	44.0149	74.3722	57.6796	60.6864	52.9528	59.4778	56.3023
Classic-HW	45.7530	45.7961	63.2067	46.5667	44.5442	51.5791	40.5051	42.7963
Box-Jenkins	43.2071	46.6772	97.2940	39.8519	39.3229	52.2111	39.5831	42.4107
LSTM	43.3844	72.3414	86.3939	56.0160	43.2336	62.8611	59.3373	40.7605

Note: The lowest value for each province is bolded

3.4 การพยากรณ์ล่วงหน้า 2 ปี

การพยากรณ์ค่าความเข้มข้น PM_{2.5} ทั้ง 8 จังหวัดตามตัวแบบที่มีประสิทธิภาพมากที่สุดในหัวข้อ 3.3 ได้ผลกราฟเส้นค่าจริงและค่าพยากรณ์ดัง Figure 5 และ 6 จะเห็นว่า PM_{2.5} ทุกจังหวัดนั้นมีฤดูกาลชัดเจน คือจะมีช่วงที่ค่า PM_{2.5} สูงเกิน 37.5 ไมโครกรัมต่อลูกบาศก์เมตร เริ่มประมาณเดือนธันวาคมเป็นต้นไป

จนถึงประมาณเดือนพฤษภาคม และจะมีช่วงค่าสูงเกิน 75.1 ไมโครกรัมต่อลูกบาศก์เมตรขึ้นไปซึ่งถือว่าเป็นช่วงที่ค่า PM_{2.5} นั้นมีผลกระทบต่อสุขภาพมากอยู่ในช่วงเดือนมีนาคมและเมษายน มีเพียงจังหวัดแพร่ที่ค่า PM_{2.5} นั้นสูงเกิน 75.1 ไมโครกรัมต่อลูกบาศก์เมตรเร็วกว่าจังหวัดอื่นๆ คือตั้งแต่ประมาณเดือนมกราคมเป็นต้นไป

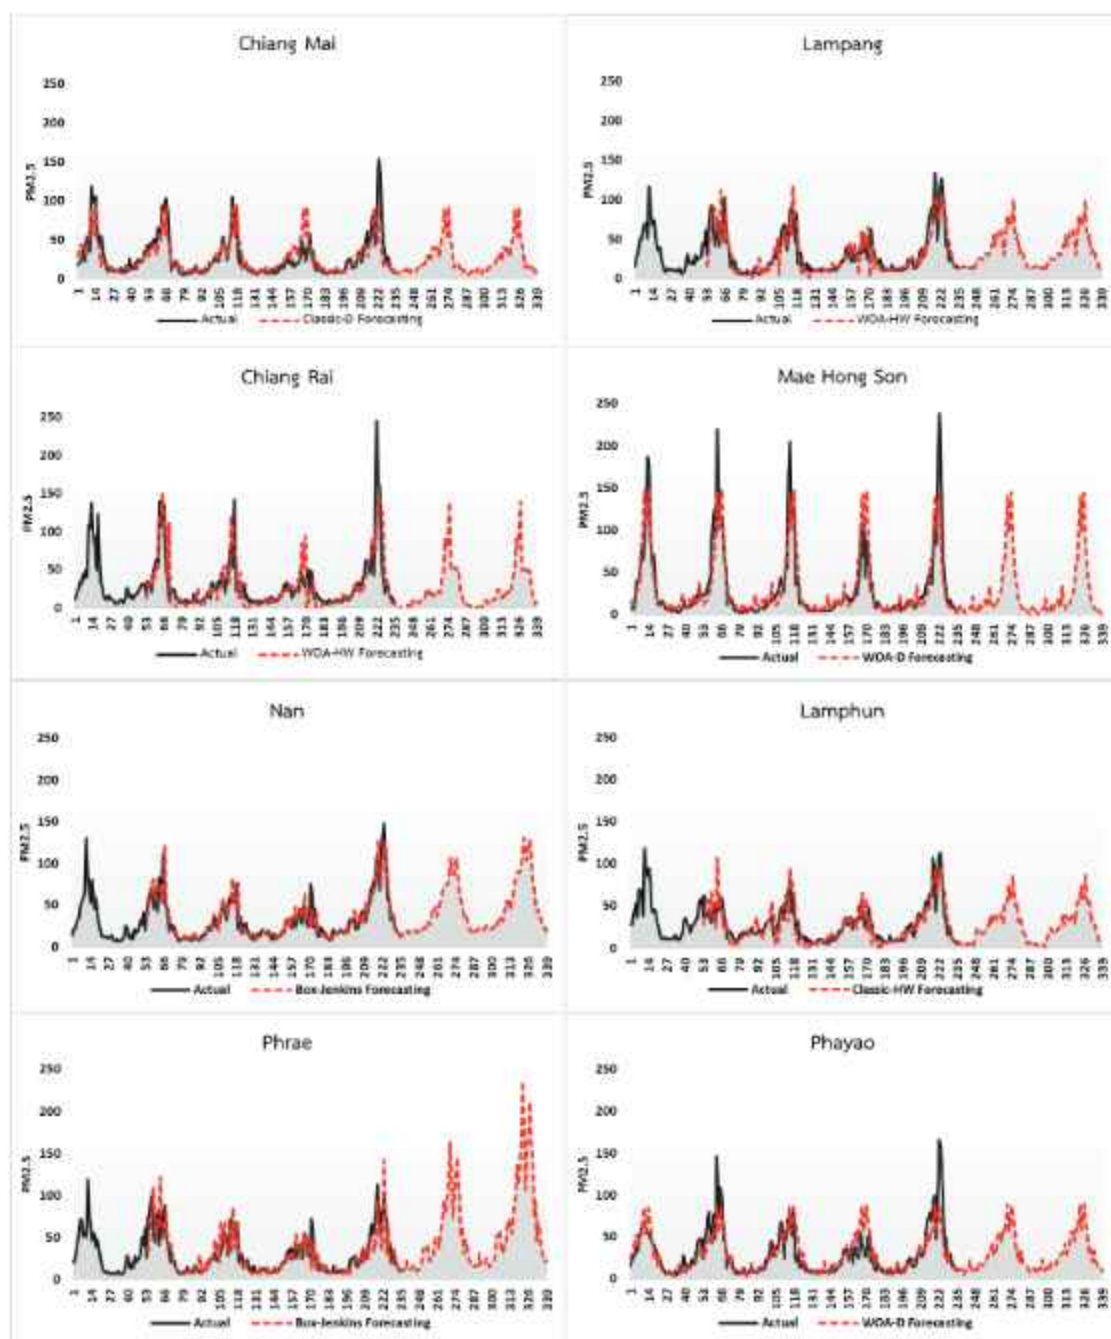


Figure 5 Comparison of actual and forecasted weekly PM2.5 values for each province using the appropriate forecasting method




Figure 6 Two-Year Ahead Forecasted Values for All Provinces

4. วิจารณ์ผล

WOA เพื่อประมาณค่าพารามิเตอร์ในวิธีการ HW จำนวน 3 ตัว และ เทคนิคการแยกส่วนประกอบ จำนวนมากถึง 54 ตัว ได้ผลลัพธ์ที่ดีกว่าการประมาณค่าพารามิเตอร์ด้วยวิธีคลาสสิกเป็นส่วนใหญ่ ซึ่งสอดคล้องกับงานวิจัย Minsan and Minsan [15, 16] ดังนั้นจากสรุปผลงานวิจัยนี้และงานวิจัย Minsan and Minsan [15, 16] ทำให้มีความเชื่อมั่นได้ว่าการใช้ WOA-HW และ WOA-D นั้นให้ผลลัพธ์ในการสร้างตัวแบบที่มีความคลาดเคลื่อนจากข้อมูลจริงต่ำ แม้ว่าค่าพารามิเตอร์จะมีจำนวนมาก WOA ก็ยังสามารถใช้งานได้ดี

5. สรุป

จาก Table 5 สรุปได้ว่าในระยะชุดข้อมูลฝึกฝน WOA-D ได้ค่าต่ำสุดฟังก์ชันวัตถุประสงค์ทั้ง 8 จังหวัด ส่วน WOA-HW ได้ค่าต่ำสุดฟังก์ชันวัตถุประสงค์ 4 จังหวัด ทำให้เชื่อได้ว่าการนำเอาวิธีวิสตติคส์มาผสมผสานกับการประมาณค่าพารามิเตอร์ของตัวแบบพยากรณ์อนุกรมเวลาเป็นวิธีการที่ดี โดยสามารถนำวิธีการเมตาฮิวริสติกส์ต่างๆ มาใช้ร่วมกันกับตัวแบบอนุกรมเวลาได้ดังผลการวิจัยที่ผ่านมาของ Minsan and Minsan [15, 16] ที่ประมาณค่าพารามิเตอร์มากที่สุด 14 ตัว และผลการศึกษานี้ที่ประมาณค่าพารามิเตอร์ได้มากขึ้น คือ 54 ตัว โดยหลักการคือเลือกวิธีการเมตาฮิวริสติกส์ที่สนใจหรือวิธีการใหม่ๆ มาทำตามขั้นตอนของงานวิจัยนี้ก็จะสามารถผสมทั้งสองส่วน คือ วิธีการเมตาฮิวริสติกส์กับเทคนิคการพยากรณ์อนุกรมเวลาได้อย่างดี

นอกจากใช้เมตาฮิวริสติกส์อื่นๆ อาจจะมีพิจารณาเทคนิคการสร้างตัวแบบพยากรณ์ที่นอกเหนือจากงานวิจัยนี้คือ เทคนิคการแยกส่วนประกอบ และเทคนิค HW โดยผู้ที่สนใจศึกษาแนวทางนี้อาจจะนำ WOA ไปประยุกต์ใช้กับเทคนิคการพยากรณ์อนุกรมเวลาอื่นๆ ก็จะเป็นงานวิจัยที่น่าสนใจเป็นอย่างมาก ทั้งนี้ผลสรุปของงานวิจัยแสดงให้เห็นแล้วว่าการประมาณค่าพารามิเตอร์จำนวนมาก เช่น 54 ตัว วิธีการเมตาฮิวริสติกส์ WOA ก็สามารถประมาณค่าพารามิเตอร์ได้

Table 5 Summary of the best-fit model of objective function RMSE for each province in the train dataset phase

Train Dataset Phase	
WOA-D	CMV, LPG, CRI, MSN, NAN, LPN, PRE, PYO
Classic-D	-
WOA-HW	LPG, CRI, LPN, PYO
Classic-HW	CMV, MSN, NAN, PRE

จากตารางที่ 6 แสดงให้เห็นว่าไม่สามารถระบุวิธีการพยากรณ์ล่วงหน้าแบบใดที่ให้ผลลัพธ์ที่ดีที่สุดอย่างแน่ชัด เนื่องจากความผันผวนของข้อมูลอนุกรมเวลา ส่งผลต่อความแม่นยำในการพยากรณ์ล่วงหน้า โดยทั่วไปแล้ว หากชุดข้อมูลฝึกอบรมมีรูปแบบคล้ายคลึงกับชุดข้อมูลทดสอบ โมเดลที่ดีในชุดข้อมูลฝึกอบรมก็มีความแนวโน้มที่จะให้ผลลัพธ์ที่ดีในชุดข้อมูลทดสอบด้วยเช่นกัน อย่างไรก็ตาม สิ่งสำคัญคือต้องตระหนักว่าความผันผวนของข้อมูลอนุกรมเวลานั้นเกิดขึ้นได้เสมอ ชุดข้อมูลฝึกอบรมและชุดข้อมูลทดสอบอาจมีความแตกต่างกัน แนวทางปฏิบัติที่แนะนำ คือ ในการพยากรณ์ล่วงหน้าควรสร้างตัวแบบหลายตัวแบบเพื่อนำมาเปรียบเทียบกันตามเกณฑ์การตัดสินใจ

Table 6 Summary of the most suitable model for each province in the test dataset phase

	Test Dataset Phase		
	RMSE	MAE	MAPE
WOA-D	MSN, PYO	PYO	-
Classic-D	CMV	-	CMV, LPG
WOA-HW	LPG	CRI	CRI
Classic-HW	CRI, LPN, PRE	CMV, LPG, LPN	LPN
Box-Jenkins	NAN	NAN, PRE	MSN, NAN, PRE
LSTM	-	MSN	PYO

6. References

- [1] Dorigo, M., 1992, Optimization, Learning and Natural Algorithms, Ph.D. Thesis, Politecnico di Milano, Italy, 140 p.
- [2] Dorigo, M. and Stützle, T., 2004, Ant Colony Optimization, MIT Press, Cambridge, MA, USA, 305 p.
- [3] Karaboga, D., 2005, An Idea Based on Honey Bee Swarm for Numerical Optimization, Technical Report-TR06, Engineering Faculty, Computer Engineering Department, Erciyes University, 10 p.
- [4] Yang, X.S., and Deb, S., 2009, Cuckoo Search Via Lévy Flights, Proceedings of World Congress on Nature & Biologically Inspired Computing (NaBIC), pp. 210-214.
- [5] Pan, W.T., 2011, A New Evolutionary Computation Approach: Fruit Fly Optimization Algorithm, Proceedings of the Conference of Digital Technology and Innovation Management, Taipei, Taiwan, pp. 382-391.
- [6] Yang, X.S., 2012, Flower pollination algorithm for global optimization, Unconventional Computation and Natural Computation, Lecture Notes in Computer Science. 7445: 240-249.
- [7] Kaewpaengjuntra, S., Somhom, S. and Saenchan, L., 2010, Electricity consumption forecasting model using hybrid Holt-Winters exponential smoothing and artificial bee colony algorithm. Information Technology Journal. 6(1): 12-17. (in Thai)
- [8] Assis, M.V.O., Carvalho, L.F., Rodrigues, J.J.P.C. and Provençal, M.L., 2013, Holt-Winters statistical forecasting and ACO metaheuristic for traffic characterization. Proceeding of 2013 IEEE International Conference on Communications (ICC), Budapest, Hungary, pp. 2524-2528.
- [9] Janta, S., Thaninpong, P. and Minsan, W., 2018, Holt-Winters Exponential Smoothing Forecasting using Flower Pollination Algorithm based Parameter Estimation, Proceeding of The 6th Academic Science and Technology Conference 2018, Bang Phli, Samut Prakan, pp. B5-40-46. (in Thai) Available Source: https://drive.google.com/file/d/1zVBvqbNqfTqrZYUmiY8wS2uN1amtOy/view?usp=drive_link, July 1, 2023. (in Thai)
- [10] Jiang, W., Wu, X., Gong, Y., Yu, W. and Zhong, X., 2020, Holt-Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption, Energy. 193: 116779.
- [11] Mauricio, C.C. and Ostia, C.F., 2023, Cuckoo search algorithm optimization of Holt-Winter method for distribution transformer load forecasting. Proceeding of the 2023 9th International Conference on Control, Automation and Robotics (ICCAR), Beijing, China, pp. 36-42.
- [12] Mirjalili, S. and Lewis, A., 2016, The whale optimization algorithm, Advances in Engineering Software. 95: 51-67.

- [13] Nadimi-Shahraki M.H., Zamani, H., Varzaneh Z.A. and Mirjalili, S., 2023, A systematic review of the whale optimization algorithm: theoretical foundation improvements and hybridizations, *Archives of Computational Methods in Engineering*. 30: 4113-4159.
- [14] Minsan, W., Saengngammuang, N., Taninpong, P. and Thumronglaohapun, S., 2021, Comparing Methods of Optimization in Solver of Excel 2019 and Whale Optimization Algorithm, *UTK Research Journal*. 15(2): 106-120. (in Thai)
- [15] Minsan, W. and Minsan, P., 2023, Incorporating Decomposition and the Holt-Winters Method into the Whale Optimization Algorithm for Forecasting Monthly Government Revenue in Thailand, *Science & Technology Asia*. 28(4): 38-53.
- [16] Minsan, W. and Minsan, P., 2024, Decomposition and Holt-Winters Enhanced by the Whale Optimization Algorithm for Forecasting the Amount of Water Inflow into the Large Dam Reservoirs in Southern Thailand, *Journal of Current Science and Technology*. 14(2): 1-16.
- [17] Ministry of Natural Resources and Environment, Pollution Control Department, Available Source: <http://air4thai.pcd.go.th/webV2/history/#>, July 30, 2023. (in Thai)
- [18] Box, G.E.P., Jenkins, G.M., Reinsel, G.C. and Ljung, G.M., 2015, *Time Series Analysis: Forecasting and Control*, 5th ed., Wiley, 712 p.
- [19] Minsan, W. and Minsan, P. and Panichkit osolkul, W., 2024, Enhancing Decomposition and Holt-Winters Weekly Forecasting of PM2.5 Concentrations in Thailand's Eight Northern Provinces Using the Cuckoo Search Algorithm, *Thailand Statistician*. 22(4) : 963-935.
- [20] Hochreiter, S. and Schmidhuber, J., 1997, Long short-term memory, *Neural Computation*. 9(8): 1735-1780.
- [21] Singhaworawong, P., (2020), *Forecasting PM2.5 in Chiang Mai using long short-term memory models*, Master Thesis, Srinakharinwirot University, Bangkok, 76 p. (in Thai)
- [22] Google Colab, Overview of Colaboratory Features, Available Source: <https://colab.research.google.com/notebooks/intro.ipynb>, May 1, 2023.